

Univerzita Karlova
Přírodovědecká fakulta
Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie (navazující magisterské studium)

Studijní obor: Kartografie a geoinformatika



Bc. Ondřej HAVELKA

**KLASIFIKA DRUHOVÉ SKLADBY LESA POMOCÍ DAT
SENTINEL-2 A LANDSAT 8**

**TREE SPECIES CLASSIFICATION USING SENTINEL-2
AND LANDSAT 8 DATA**

Diplomová práce

Vedoucí diplomové práce: **RNDr. Přemysl Štych, Ph.D.**

Praha 2018

Vysoká škola: Univerzita Karlova

Fakulta: Přírodovědecká

Katedra: Aplikované geoinformatiky a kartografie

Akademický rok: 2017/2018

Zadání diplomové práce

Pro Ondřeje Havelku

Obor Kartografie a geoinformatika

Název tématu: Klasifikace druhové skladby lesa pomocí dat Sentinel-2 a Landsat 8

Zásady pro vypracování

Hlavním cílem diplomové práce je zhodnocení využitelnosti vybraných klasifikačních algoritmů k rozlišení druhové skladby lesů na vybraných území Česka. Použitím družicových snímků Sentinel-2 a Landsat 8 bude zkoumáno, zda lepší prostorové a spektrální rozlišení dat Sentinel-2 má vliv na lepší přesnost klasifikace a s jakou přesností lze docílit klasifikaci lesních porostů na úrovni jednotlivých druhů.

Soubor trénovacích a kontrolních množin v předkládané práci bude vycházet z dat druhové skladby lesů od Ústavu pro hospodářskou úpravu lesů. Legenda klasifikace bude vycházet z místních podmínek řešeného území a zavedených lesnických nomenklatur.

Použity budou klasifikační algoritmy Support Vector Machine, Neural Network a Maximum Likelihood. Nastavením a podrobným testováním/zhodnocením hlavních parametrů klasifikačních algoritmů bude snahou dosažení co nejvyšší klasifikační přesnosti. V diskusní části budou podrobně diskutovány použité metodické postupy, dosažené přesnosti klasifikace a ostatní výsledky. Diplomová práce bude obsahovat rešerši relevantních literárních zdrojů.

Rozsah grafických prací: dle potřeby

Rozsah průvodní zprávy: 50–100 stran (dle potřeby)

Seznam odborné literatury:

IMMITZER, M.; VUOLO, F.; ATZBERGER, C. (2016): First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe. Remote Sensing, 8, č. 166.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. (2011): Support vector machines in remote sensing: A review. ISPRS Journal of Photogrammetry and Remote Sensing. Vydání 66, č. 3, s. 247-259.

RACZKO, E., ZAGAJEWSKI, B. (2017): Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images, European Journal of Remote Sensing, Vydání 50, č. 1, s. 144-154.

TOPALOGLU, R., H.; SERTEL, E.; MUSAOGU, N. (2016): Assessment of Classification Accuracies of SENTINEL-2 and LANDSAT-8 Data for Land Cover/ Use Mapping. International Archives of the Photogrammetry. Remote Sensing and Spatial Information Sciences. Vydání XLI-B8, 2016. s. 1055-1059.

Vedoucí diplomové práce: RNDr. Přemysl Štych, Ph.D.

Datum zadání diplomové práce: 05. 01 .2016

Termín odevzdání diplomové práce: 31. 07. 2018

Platnost tohoto zadání je po dobu jednoho akademického roku.

.....

Vedoucí diplomové práce

V Praze dne 05. 01. 2018

.....

Garant oboru

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci zpracoval samostatně a že jsem uvedl všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

Jsem si vědom toho, že případné použití výsledků, získaných v této práci, mimo Univerzitu Karlovu je možné pouze po písemném souhlasu této univerzity.

Svoluji k zapůjčení této práce pro studijní účely a souhlasím s tím, aby byla řádně vedena v evidenci vypůjčovatelů.

V Praze dne 30. 7. 2018

.....

Bc. Ondřej Havelka

Poděkování

Rád bych tímto způsobem poděkoval všem, kteří mi pomohli s vypracování této práce. Velké díky patří především RNDr. Přemyslu Štychovi, Ph.D. za odborné rady, připomínky a všechnen věnovaný čas z pozice vedoucího mé diplomové práce. Děkuji také Ústavu pro hospodářskou úpravu lesů za poskytnutá data. V neposlední řadě bych rád poděkoval své rodině a nejbližším přátelům za podporu v průběhu celého studia.

ABSTRAKT

Hlavním cílem diplomové práce je zhodnocení využitelnosti vybraných klasifikačních algoritmů k rozlišení druhové skladby lesů na území Česka. Použitím družicových snímků Sentinel-2 a Landsat 8 je zkoumáno, zda lepší prostorové rozlišení ovlivní výslednou klasifikaci a zda díky technologickému pokroku lze docílit klasifikace lesních porostů na úrovni jednotlivých druhů. Základem každé řízené klasifikace je vhodně zvolený soubor trénovacích a kontrolních množin, který v předkládané práci vychází z polygonové vrstvy, popisující druhovou skladbu, jejímž autorem je Ústav pro hospodářskou úpravu lesů. Na základě rešerše aktuální odborné literatury jsou v předkládané práci použity klasifikační algoritmy Support Vector Machine, Neural Network a Maximum Likelihood. Je snahou jejich modifikacemi, které vychází z výsledků odborných prací, dosáhnout co nejvyšší klasifikační přesnosti. Veškeré výsledky jsou doplněny tabulkami, grafy a mapami, které uceleně a přehledně shrnou odpovědi na stanovené cíle předkládané práce.

Klíčová slova: dálkový průzkum země, klasifikace, druhová skladba lesa, Sentinel-2, Landsat 8, Support Vector Machine, Neural Network, Maximum Likelihood

ABSTRACT

The main objectives of this master thesis are to evaluate and compare chosen classification algorithm for the tree species classification. With usage of satellite imagery Sentinel-2 and Landsat 8 is examined whether the better spatial resolution affects the quality of the resulted classification. According to past case studies and literature was chosen supervised algorithms Support Vector Machine, Neural Network and Maximum Likelihood. To achieve the best possible results of classification is necessary to find a suitable choice of parameters and rules. Based on literature was applied different settings which were subsequently evaluated by cross validation. All results are accompanied by tables, charts and maps which comprehensively and clearly summarize the answers to the main objectives of the thesis.

Key words: remote sensing, classification, tree species, Sentinel-2, Landsat 8, Support Vector Machine, Neural Network, Maximum Likelihood

OBSAH

PŘEHLED POUŽITÝCH ZKRATEK	9
SEZNAM GRAFŮ, OBRÁZKU A TABULEK.....	11
1 ÚVOD A CÍLE PRÁCE	13
2 ÚVOD DO PROBLEMATIKY	15
2.1 Dálkový průzkum Země.....	15
2.2 Spektrální projev vegetace	16
2.3 Klasifikace.....	17
2.3.1 Neural Network.....	17
2.3.2 Support Vector Machine	18
2.3.3 Maximum Likelihood	19
2.4 Rešerše zahraniční literatury	19
3 ZÁJMOVÉ ÚZEMÍ	21
4 DATA A METODIKA	23
4.1 Použitá data	23
4.1.1 Vektorová data.....	23
4.1.2 Stanovení klasifikačního systému.....	24
4.1.3 Rastrová data.....	25
4.2 Použitý software.....	29
4.3 Metodika	30
4.3.1 Předzpracování satelitních snímků	31
4.3.2 Trénovací množiny	32
4.3.3 Použité klasifikační algoritmy	36
4.3.4 Přesnost klasifikace.....	39
5 VÝSLEDKY	43
5.1 Porovnání přesnosti řízených klasifikací satelitních snímků	43
5.2 Hodnocení jednotlivých klasifikátorů	47
5.3 Mapy klasifikovaného území použitými algoritmy	56

6	DISKUZE	64
6.1	Volba nejvhodnějšího souboru trénovacích a kontrolních množin.....	64
6.2	Spektrální pásma zpracovaných scén.....	66
6.3	Hodnocení přesnosti použitých klasifikačních algoritmů	66
7	ZÁVĚR.....	70
	SEZNAM POUŽITÉ LITERATURY	71
	SEZNAM POUŽITÝCH ZDROJŮ DAT.....	75
	SEZNAM PŘÍLOH.....	76

PŘEHLED POUŽITÝCH ZKRATEK

BOA	Bottom of Atmosphere
CE	Comission error
DPZ	Dálkový průzkum země
ESA	Evropská kosmická agentura
LAI	Leaf area index
L8	Landsat 8
ML	Maximum Likelihood
NASA	National Aeronautics and Space Administration
NN	Neural Network
OA	Overall accuracy
OBIA	Object Based Image Analysis
OE	Omission error
OLI	Operational Land Imager
OPRL	Oblastní plán rozvoje lesa
PA	Producer accuracy
PLO	Přírodní lesní oblast
Poly 6	Polynomická funkce 6. stupně
RBF	Radiální bázová funkce
ROI	Regions of Interest
SPT	Strukturovaný porostní typ
SVM	Support Vector Machine
S2	Sentinel-2
TIRS	Thermal InfraRed Sensor
TOA	Top of Atmosphere
TTC	Training Treshold Contribution
TR	Training Rate
TM	Training Momentum
UA	User accuracy

USGS	United States Geological Survey
UTM	Universal Transverse Mercator
ÚHUL	Ústav pro hospodářskou úpravu lesů

SEZNAM GRAFŮ, OBRÁZKU A TABULEK

Graf 1: Porovnání celkové přesnosti (OA) klasifikačních algoritmů	44
Graf 2: Relativní zastoupení tříd klasifikovaných metodou Maximum Likelihood.	47
Graf 3: Relativní zastoupení tříd klasifikovaných metodou Support Vector Machine s radiální bázovou funkcí jádrové transformace	48
Graf 4: Relativní zastoupení tříd klasifikovaných metodou Support Vector Machine s polynomickou funkcí jádrové transformace 6. stupně	50
Graf 5: Relativní zastoupení tříd klasifikovaných metodou Neural Network s původními parametry	51
Graf 6: Relativní zastoupení tříd klasifikovaných metodou Neural Network s první modifikací	53
Graf 7: Relativní zastoupení tříd klasifikovaných metodou Neural Network s druhou modifikací	54
Graf 8: Relativní zastoupení tříd klasifikovaných metodou Neural Network se třetí modifikací	55
Obrázek 1: Křivky spektrální odrazivosti vybraných dřevin	17
Obrázek 2: Poloha zájmového území	21
Obrázek 3: Současná dřevinná skladba v PLO č. 7	22
Obrázek 4: Porovnání prostorového rozlišení v nepravých barvách pro PLO 7	29
Obrázek 5: Metodika práce	30
Obrázek 6: Špatně zařazená třída č. 9 bříza bělokorá	33
Obrázek 7: Špatně zařazená třída č. 3 borovice lesní	34
Obrázek 8: Korelační diagram pro Sentinel-2	37
Obrázek 9: Korelační diagram pro Landsat 8	37
Obrázek 10: Poloha trénovacích a kontrolních množin na území PLO 7	40
Obrázek 11: Výřez klasifikovaného území z dat Sentinel-2 algoritmem ML	57
Obrázek 12: Výřez klasifikovaného území z dat Landsat 8 algoritmem ML	57
Obrázek 13: Výřez klasifikovaného území z dat Sentinel-2 algoritmem SVM – RBF ..	58
Obrázek 14: Výřez klasifikovaného území z dat Landsat 8 algoritmem SVM – RBF ...	58
Obrázek 15: Výřez klasifikovaného území z dat Sentinel-2 algoritmem SVM – POLY6	59

Obrázek 16: Výřez klasifikovaného území z dat Landsat 8 algoritmem SVM – POLY6	59
Obrázek 17: Výřez klasifikovaného území z dat Sentinel-2 algoritmem NN – Default	60
Obrázek 18: Výřez klasifikovaného území z dat Landsat 8 algoritmem NN – Default .	60
Obrázek 19: Výřez klasifikovaného území z dat Sentinel-2 algoritmem NN – Mod1 ...	61
Obrázek 20: Výřez klasifikovaného území z dat Landsat 8 algoritmem NN – Mod1....	61
Obrázek 21: Výřez klasifikovaného území z dat Sentinel-2 algoritmem NN – Mod2...	62
Obrázek 22: Výřez klasifikovaného území z dat Landsat 8 algoritmem NN – Mod2....	62
Obrázek 23: Výřez klasifikovaného území z dat Sentinel-2 algoritmem NN – Mod3 ...	63
Obrázek 24: Výřez klasifikovaného území z dat Landsat 8 algoritmem NN – Mod3....	63
Tabulka 1: Charakter smíšení	23
Tabulka 2: Spektrální pásma družice Sentinel-2	26
Tabulka 3: Spektrální pásma družice Landsat 8	28
Tabulka 4: Charakteristika trénovacích množin	34
Tabulka 5: Matice divergencí trénovacích množin pro Sentinel-2.....	35
Tabulka 6: Matice divergencí trénovacích množin pro Landsat 8.....	36
Tabulka 7: Charakteristika kontrolních množin	40
Tabulka 8: Matice divergencí kontrolních množin pro Sentinel-2	41
Tabulka 9: Matice divergencí kontrolních množin pro Landsat 8.....	42
Tabulka 10: Porovnání celkové přesnosti (OA) a kappa indexu	43
Tabulka 11: Rozloha klasifikovaných tříd z dat Sentinel-2.....	45
Tabulka 12: Rozloha klasifikovaných tříd z dat Landsat 8	46
Tabulka 13: Hodnocení přesnosti klasifikátoru ML	48
Tabulka 14: Hodnocení přesnosti klasifikátoru SVM – RBF	49
Tabulka 15: Hodnocení přesnosti klasifikátoru SVM – Poly6	50
Tabulka 16: Hodnocení přesnosti klasifikátoru NN – Default	52
Tabulka 17: Hodnocení přesnosti klasifikátoru NN – Mod1	53
Tabulka 18: Hodnocení přesnosti klasifikátoru NN – Mod2.....	54
Tabulka 19: Hodnocení přesnosti klasifikátoru NN – Mod3.....	56

1 ÚVOD A CÍLE PRÁCE

Předpokladem k zachování trvale udržitelných lesních ploch je jejich neustálý monitoring a výzkum v terénu. S měnící se dobou, která je typická elektronizací procesů za účelem zefektivnění jejich fungování, jsou v oboru lesnictví stále více využívány metody dálkového průzkumu země (dále též DPZ). Jedním z hlavních principů tohoto způsobu výzkumu je určení parametrů zkoumaného objektu na základě jeho spektrální odrazivosti zaznamenané senzorem, který však nemusí být v přímém kontaktu. Díky dlouholetému vývoji jak technologickému, tak znalostnímu, lze v dnešní době celkem snadno rozlišit listnaté od jehličnatých lesů na území o velikosti v řádech stovek kilometrů. Právě tento způsob odlišení dvou druhově rozdílných lesních porostů se nazývá klasifikace. Proces klasifikace je v DPZ založen na třídění pixelů dle jejich spektrální odrazivosti. Existují dva způsoby klasifikace satelitních dat. Prvním je řízená a druhým je neřízená klasifikace. Zatímco pro řízenou klasifikaci je nutné nejdříve stanovit legendu, tak neřízená klasifikace shlukuje spektrálně separované kategorie, které jsou následně přiřazeny klasifikačním třídám legendy. V předkládané práci bude provedena řízená klasifikace, jejímž základem jsou vhodně zvolená trénovací data. Snahou autora bude rozlišit 6 tříd lesního porostu. V práci bude využita polygonová vrstva charakterizující strukturovaný porostní typ, jejímž autorem je Ústav pro hospodářskou úpravu lesů (dále též ÚHUL). Zmíněná instituce se mimo jiné zabývá zpracováním Oblastních plánů rozvoje lesa (dále též OPRL), což jsou obsáhlé dokumenty, které slouží jako metodický nástroj státní lesnické politiky a doporučují zásady hospodaření v lesích. Plány jsou zpracovávány dle přírodních lesních oblastí (dále též PLO), což jsou území vymezená v rámci průzkumu lesních stanovišť (ÚHUL, 2018). Pro zpracování klasifikace 6 zvolených typů lesního porostu byla zvolena PLO 7 Brdská vrchovina.

Monitoring zemského povrchu a jeho následná klasifikace dle spektrálních charakteristik, kterých využívají v samotném procesu algoritmy, se liší způsobem třídění příznakového prostoru. Algoritmus Support Vector Machine byl v práci Edwina Raczkho a Bogdana Zagajewski (2017) označen za nejlepší klasifikátor k vypořádání se s komplexními klasifikačními problémy, kterými jsou např. odlišení druhů lesního porostu. Využitím těchto moderních algoritmů lze tedy dosáhnout přesnějších výsledků klasifikace. Mezi dalšími byl zmíněn i klasifikátor Neural Network, který dosahuje obdobně vysokých hodnot při složitějším třídění dat DPZ. Z důvodu snahy

o co nejkvalitnější zpracování klasifikace druhové skladby lesa zvolených území, budou v předkládané práci využity zmíněné dva algoritmy, které doplní konvenční algoritmus Maximum Likelihood.

Technologický pokrok dnešní doby v DPZ přináší data vyššího prostorového rozlišení s větším počtem zpracovávaných spektrálních pásem. Základním předpokladem této práce je přínos v podobě zlepšení přesnosti klasifikace vlivem zmíněných inovací. Evropská komise přispěla na poli satelitního snímání v roce 2015 vypuštěním družice Sentinel-2. Ta by díky lepšímu prostorovému rozlišení (10/20/60 m), vyššímu počtu spektrálních pásem (13), a především jejich rozmístění v pásmu blízkého infračerveného záření, měla předčít kvality dlouholetého zdroje družicových dat Landsat 8. Porovnáním celkových přesností klasifikace u těchto dvou zmiňovaných satelitních snímků se bude autor snažit prokázat zejména přínos lepšího prostorového rozlišení o 10 metrů, ale také využitelnost specifických spektrálních pásem pro klasifikaci land coveru.

Předkládaná práce si klade následující cíle:

- 1) Porovnání přesnosti současných klasifikačních algoritmů,
- 2) Klasifikace druhové skladby zvolených lesních porostů zájmového území,
- 3) Prokázání přidané hodnoty Sentinel-2 v podobě lepšího prostorového rozlišení.

Text bude systematicky členěn na úvod do problematiky, který slouží jako teoretický přehled základních principů DPZ. Následovat bude popis zájmového území s jeho stručnou charakteristikou. Za účelem podrobného vysvětlení použitých metod a popsání procesů, které budou v práci vykonány, bude sepsána kapitola o datech a metodice. Na ni autor naváže představením výsledků, které následně kriticky zhodnotí. Závěr práce pak shrne nejdůležitější poznatky získané diplomovou prací.

2 ÚVOD DO PROBLEMATIKY

2.1 Dálkový průzkum Země

Využití snímků, které jsou získávány z družic na zemském orbitu, nachází v posledních letech stále širší uplatnění. Dálkový průzkum Země se stává stále častějším nástrojem pro analýzy struktur zemského povrchu a hodnocení změn na něm probíhajících. S progresivním vývojem nových, a stále dokonalejších zařízení pro snímání zemského povrchu, se neustále zvyšuje kvalita získaných snímků a s ní spojená přesnost daných analýz, hodnocení a také např. klasifikací.

V oboru lesnictví je DPZ nenahraditelným nástrojem pro mapování rozsáhlých lesních oblastí jak z hlediska druhové skladby porostů, tak jeho zdravotního stavu. Tento přístup ke správě lesů přináší významnou ekonomickou úsporu, a to zejména z důvodu úspory času. Při práci se satelitními snímky, které v dnešní době dosahují prostorového rozlišení v řádech metrů, je pomocí automatizovaných algoritmů možné během několika málo minut odlišit zdravý les od porostu postiženého různými typy disturbancí. S novými senzory, umístěnými na družicích, je rozšiřováno taktéž spektrální rozlišení. Díky této inovaci je možné získávat zcela nové či výrazně kvalitnější informace o zkoumaném objektu.

Principy DPZ

Dálkový průzkum země je způsob získávání a analyzování dat za účelem získání informací bez použití nástroje, který by byl v přímém kontaktu s objektem. Základním principem je měření elektromagnetického záření odraženého nebo vyzařovaného samotným zemským povrchem. K tomu slouží tzv. radiometr, který může být nesen letadlem či družicí. Mezi základní parametry tohoto zařízení patří prostorové a spektrální rozlišení. Zatímco prostorové rozlišení definuje, jak velká plocha na zemském povrchu odpovídá jednomu pixelu na snímku, spektrální rozlišení stanovuje šířku elektromagnetického spektra, kterou je daný senzor schopný pojmout a také počet pásem, do kterých je tento interval rozdělen. S novými senzory, umístěnými na družicích, je rozšiřováno jak rozlišení prostorové, tak spektrální. Díky této inovaci je možné získávat zcela nové či výrazně kvalitnější informace o zkoumaném objektu.

2.2 Spektrální projev vegetace


V předchozí kapitole bylo zmíněno, že základním principem DPZ je měření odražené či vyzářené energie na úrovni zemské atmosféry. Pro stanovení fyzikálních vlastností daného objektu či látky využíváme porovnání hodnot naměřených radiometrem s hodnotami známými z předchozích měření (Kolář, Halounová, Pavelka, 1997). Lze konstatovat, že každý objekt či látka mají svou specifickou hodnotu spektrální odrazivosti. Ta je odvozena ze spektrální křivky odrazivosti, která popisuje závislost mezi odrazivostí a vlnovou délkou dané látky (Dobrovolný, 1998). Základní znalosti o prostředí, ve kterém se zkoumaný objekt nachází, stejně tak určité vlastnosti daného objektu (např. vlhkost, stáří, hustota), mohou pomoci při volbě spektrálních pásem za účelem lepších výsledků následných aplikačních procesů (Kolář, Halounová, Pavelka, 1997).

Spektrální projev porostu určitého druhu je výsledkem odrazivých a emisních vlastností všech částí rostliny i prostředí, ve kterém se vyskytuje. Pokud vegetace není příliš hustá, přispívá do hodnoty celkové odrazivosti vegetačního povrchu i odrazivost půdy. Mírou hustoty povrchu je index listové plochy LAI (leaf area index). Právě příspěvek od listů či jehlic stromů je dominantní a je výslednicí jednotlivých prvků, zejména buněčné tekutiny, celulózy, tuků, ligninu, proteinů, cukrů a oleje. „Kvantitativně se spektrální průběhy různě odlišných rostlin od sebe liší, ale vesměs vykazují určité společné rysy, které lze označit za typické pro vegetaci.“ (Kolář, Halounová, Pavelka, 1997, s. 40) V oblasti blízkého infračerveného záření je výraznější rozdíl mezi půdou a vegetací. Ten je závislý nejen na hustotě vegetace, ale také na orientaci listů vůči Slunci a na výšce Slunce nad obzorem (Kolář, Halounová, Pavelka, 1997).

Charakterizovat spektrální odrazivost vegetace lze pomocí rozdělení do tří hlavních oblastí, které odpovídají třem faktorům určujícím velikost spektrální odrazivosti. První z nich je oblast pigmentační absorpce ve viditelném pásmu 0,4 μm až 0,7 μm . Průběh spektrální křivky je formován pigmentační látkou, kterou je u většiny rostlin chlorofyl. „Nárůst obsahu chlorofylu se projeví nejdříve prohloubením absorpčního pásu 0,68 μm , jeho mírným posunem do větších vlnových délek a snižováním maxima odrazivosti v zelené barvě.“ (Kolář, Halounová, Pavelka, 1997, s. 41) Druhou oblast lze nalézt v pásmu blízkého infračerveného záření od 0,7 μm až 1,3 μm , která je ovlivněna především morfologickou strukturou listu či jehlice. Základní stavební látku zde tvoří celulóza, která se vyznačuje nízkou pohltivostí záření.

Skutečná odrazivost v blízkém infračerveném pásmu je způsoben několikanásobným odrazem uvnitř listu či jehlice. V rozmezí hodnot 1,3 μm do 3,0 μm lze definovat třetí oblast, kterou nazýváme oblastí vodní absorpce. Ta se vyznačuje výraznými absorpčními pásy vody na vlnových délkách 1,4 μm , 1,9 μm a 2,7 μm . Relativní množství odražené energie od různého typu vegetace je znázorněno na Obrázku 1. Zatímco ve viditelné části spektra (světle šedý pás) jsou rozdíly v odrazivosti minimální, značně rozdílných hodnot dosahují odlišné typy vegetace v pásmu blízkého infračerveného záření (tmavě šedý pás).

Obrázek 1: Křivky spektrální odrazivosti vybraných dřevin (zdroj: Hájek a kol., 2016)



2.3 Klasifikace

2.3.1 Neural Network

Algoritmus neuronových sítí je inspirován procesy v lidském mozku. Simuluje složitou soustavu neuronů (uzlových bodů, resp. nodes), která je schopná přijímat více vstupů, ale vytvořit jeden výstup. Tento způsob automatického zpracování neboli učení se, je zajištěn dynamickým propojením všech uzlových bodů. Neural Network (dále též NN) jsou na vstupu relativně tolerantní k neúplným datům. Jakmile již proběhlo „jedno učení“, nemusí být nová data zcela kompletně popsána.

Bylo zjištěno, že NN s jednou trénovací množinou pro danou třídu dosahuje obdobně kvalitních výsledků klasifikace jako konvenční řízené klasifikační algoritmy se čtyřmi trénovacími množinami pro danou třídu (Hepner, 1990). Mezi hlavní parametry, které přímo ovlivní výsledek klasifikace patří:

- 1) Training Treshold Contribution (dále též TTC)
 - Slouží ke stanovení vah jednotlivých uzlů,
 - větší váha některého z uzlů může vést ke špatné generalizaci výstupu.
- 2) Training Rate (dále též TR)
 - Určuje rozsah jednotlivých uzlů,
 - větší rozsah urychlí výpočet, ale může vést k výkyvům či nespojitosti výstupu.
- 3) Training Momentum (dále též TM), Training RMS Exit Criteria, Number of Hidden Layers, počet iterací atd.

2.3.2 Support Vector Machine

Klasifikační algoritmus Support Vector Machine (dále též SVM), je zástupcem řízených neparametrických metod odvozených ze statistických teorií, který nabízí často dobré klasifikační výsledky pro komplexní a nějakým způsobem porušená data (ENVI, SVM background, 2017). Základem metody je rozdělení prostoru podpůrným vektorem tak, aby si obě klasifikační třídy zachovaly maximální vzdálenost od daného vektoru (QC-Expert, SVM Background, 2013). V porovnání s alternativními metodami jako např. Neural Network může dosáhnout SVM porovnatelných hodnot klasifikačních přesností s menším počtem trénovacích dat (Mountrakis a kol., 2011).

Mezi základní parametry algoritmu SVM patří jádrová transformace (kernel type) a chybový parametr C (C parameter). Volba funkce jádrové transformace je klíčovým faktorem, který má přímý vliv na výsledky klasifikace. Nastavení samotné jádrové funkce může vést např. k přílišnému vyhlazení klasifikovaných tříd ve výsledcích nebo také k jejich přesahu (Mountrakis a kol., 2011).

- 1) Jádrová transformace:
 - a. Polynomická – $K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0,$
 - b. Radiální bázové funkce (dále též RBF) – $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0,$
 - c. Lineární – $K(x_i, x_j) = x_i^T x_j.$

Kde: γ = gamma parametr v jádrové funkci, d = stupeň polynomu, r = systematická chyba měření.

2) Chybový parametr C

Vymezuje hranici mezi zařazením do chybových nebo do hraničních hodnot.

2.3.3 Maximum Likelihood

Široce užívaným algoritmem, který je řazen do kategorie klasifikátorů per-pixel, je metoda řízené klasifikace s názvem Maximum Likelihood. Funguje na principu výpočtu pravděpodobnosti, s jakou klasifikovaný pixel spadá do určité třídy. Předpokladem je normální rozdělení pixelů v trénovacích datech (Lillesand et al., 2014). Klasifikátor řízen dle předem stanovených trénovacích množin. Jejich přesná volba je základem pro kvalitní klasifikaci snímku, jelikož i jeden či dva špatně kategorizované pixely v dané trénovací množině mohou mít zásadní vliv na výsledek klasifikace. Pro každý pixel je kvantitativně hodnocen rozptyl hodnot, kovariance i korelace každé třídy a hodnoty stejných pravděpodobností tvoří izolinie. Klasifikovaný pixel je zařazen do té třídy, do které s největší pravděpodobností spadá (Bolstad, Lillesand, 1991). Podstatným parametrem tohoto klasifikátoru je stanovení prahové hodnoty pravděpodobnosti. Pokud je zjištěná pravděpodobnost nižší než stanovená hraniční hodnota, je pixel neklasifikován.

1) Stanovení prahové hodnoty:

- a. Žádná – prahová hodnota není součástí výpočtu,
- b. Jedna hodnota – výpočet pracuje s jednou stanovenou hodnotou,
- c. Více hodnot – pro každou třídu je prahová hodnota stanovena jinak.

2.4 Rešerše zahraniční literatury

Jak uvádí Topaloglu, Sertel a Musaoglu (2016) ve své studii, stanovení klasifikační přesnosti je nedílnou součástí každého klasifikačního výstupu. Pro svou práci, která se zabývá porovnáním klasifikačních přesností použitých klasifikačních algoritmů na optických datech, si zvolili snímky z družic Landsat 8 a Sentinel-2. Na těchto datech se rozhodla provést výzkum za účelem zhodnocení přesnosti dvou klasifikačních algoritmů na dvou odlišně získaných optických datech z družic. Před samotným procesem klasifikace provedla převzorkování obou snímků o 6 spektrálních pásů do prostorového rozlišení 30 m, aby bylo možné vytvořit porovnatelné mapy krajinného

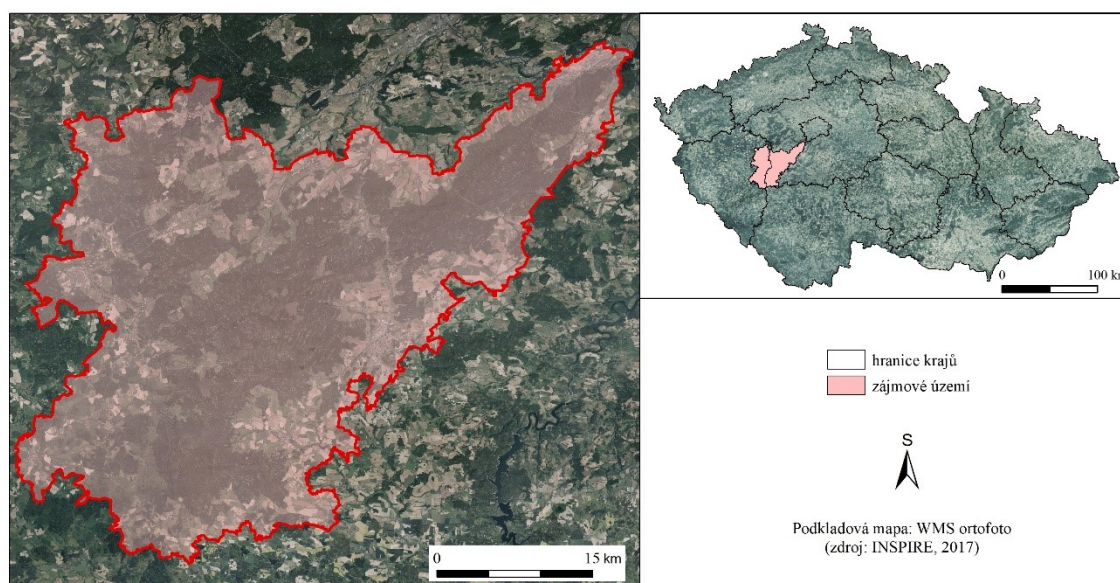
pokryvu. Aplikovala klasifikátory Support Vector Machine a Maximum Likelihood, které se řadí do kategorie řízené klasifikace. K tomuto procesu je zapotřebí trénovacích množin, kterých musí být dostatečné množství v dostatečném rozsahu, aby byla výsledná klasifikace co nejpřesnější. Většinou SVM vytváří lepší výsledky v porovnání s MLC pro všechny předem definované třídy. MLC jeví nedostatky především v důsledku spektrálního mixování pixelů při 30 m rozlišení u třídy zahrnující dopravní síť, průmyslové zóny, letiště apod. Hodnocení přesnosti klasifikačních výstupů bylo využito v této práci chybové matice. Pro klasifikátor MLC bylo dosaženo celkové přesnosti 70,60 % u snímku z Landsat 8 a 76,40 % u snímku ze Sentinel-2. Přesnějším klasifikátorem dle chybové matice je SVM, který dosáhl hodnot 81,67 % pro Landsat 8 a 84,17 % pro Sentinel-2.

Další, kdo se již zabýval klasifikací optických dat z družice Sentinel-2 byl Immitzer (2016), který, jak již byl zmíněno v kapitole 2, klasifikoval typy lesních porostů na území Střední Evropy. Uvedený výzkum si klade za cíl zejména porovnat výstupy objektově orientované klasifikace (dále též OBIA) s výsledky klasifikace pixelové, ale také určit, která spektrální pásma se nejvíce podílejí na klasifikační přesnosti. Z výsledků vyplývá, že klasifikované typy lesního porostu jeví obdobné spektrální příznaky, a tudíž ve výsledku vznikají velké překryvy jednotlivých tříd. V závěru je taktéž zmiňováno, že oba typy klasifikace nedosáhly uspokojivých výsledků (OBIA – 66,2 %, Random Forest – 63,5 %). V obou případech jsou hodnoty dosažených přesností nižší než v jiných studiích, které pracují se satelitními daty s vyšším prostorovým rozlišením (např. WorldView-2). Hlavní důvody zjištěných obtíží vychází z faktu, že zvolené lesní plochy jsou charakteristické heterogenní a vysoce fragmentovanou distribucí jednotlivých druhů lesního porostu. Výsledky klasifikací jsou často lepší pro dominantní třídy na daném území, což je nejvíce evidentní v objektově orientovaném přístupu, protože větší polygony (referenční data) znamenají více referenčních pixelů pro danou třídu. Dalším výstupem studie jsou tři spektrální pásma, zvolená jako nejvhodnější, pro klasifikaci jednotlivých druhů lesní vegetace ze snímků družice Sentinel-2 (B2 – blue, B5 – Red Edge 1, B11 – Shortwave Infrared 1). To jen potvrzuje shodnost s dalšími obdobnými pracemi, které zdůrazňují vysokou hodnotu pásma red-edge a shortwave infrared pro mapování vegetace (modré pásmo je taktéž důležité) (Immitzer, 2016).

3 ZÁJMOVÉ ÚZEMÍ

V rámci průzkumu lesních stanovišť na základě geologických, klimatických, orografických a fytogeografických podmínek, byla vymezena území, která Ústav pro hospodářskou úpravu lesů nazývá Přírodní lesní oblasti. Česká republika je rozčleněna na 41 přírodních lesních oblastí. Pro účely této práce bylo zvoleno území Brdské vrchoviny.

Obrázek 2: Poloha zájmového území (zdroj: vlastní zpracování dat ArcČR 3.3)




Brdská vrchovina

Přírodní lesní oblast č. 7. Brdská vrchovina má katastrální výměru 982,87 km² a jak lze na Obrázku 2 vidět, rozkládá se z téměř 67 % na území Středočeského kraje (bývalé okresy Praha západ, Beroun, Příbram) a z 33 % na území Plzeňského kraje (Plzeň jih, Rokycany, včetně vojenských lesů). Zajímavý je rozsah lesní vegetace, který činí 66 % z celkové rozlohy modelového území, tedy téměř 659 km². Na Obrázku 3 můžeme vidět, že nejrozšířenější jsou jehličnany, které zabírají více jak 90 % Brdské vrchoviny (ÚHUL, 2017).

Reliéf přírodní lesní oblasti 7 – Brdská vrchovina má většinou charakter členité vrchoviny s výškovou členitostí 200–300 m. Celé území spadá do pomoří Severního moře. Hlavními povodími jsou zde Berounka a Vltava. Ani jedna z nich však přímo do oblasti nezasahuje. Geologicky je oblast součástí souboru starých útvarů,

které zahrnujeme pod společným názvem Barrandien. Ráz oblasti udávají křemenné slepence a pískovce kambria, které zcela převládají v centrálních Brdech a silně se uplatňují v jižních Brdech (rožmitálských) i v Hřebenech (od Kytína k údolí Litavky). Většinu oblasti zaujímá Brdský bioregion. Na severovýchodě zasahuje do podoblasti Karlštejnský bioregion a na jihu okrajově Blatenský bioregion. Brdský bioregion je tvořen ostrovem ploché hornatiny na břidlicích. Typická část má chladnější a vlhčí klima a převážně leží v 5. jedlovo-bukovém vegetačním stupni. V 19. století se počaly porosty s původní dřevinnou skladbou (buk, dub, jedle, méně smrk a borovice) postupně přeměňovat na hospodářsky výhodnější smrk, takže dnes v Brdech převažují lignikultury smrku, silně poškozované větrnými kalamitami.

Obrázek 3: Současná dřevinná skladba v PLO č. 7 (zdroj: ÚHUL, 2001)



4 DATA A METODIKA

4.1 Použitá data

Vzhledem k zaměření této diplomové práce bylo potřeba získat satelitní snímky pro účely klasifikace lesního porostu a data z terénu pro tvorbu nejvhodnějšího souboru trénovacích i kontrolních množin, které jsou také nazývány Regions of Interest (dále též ROI).

4.1.1 Vektorová data

Pro účely této práce bylo využito datových zdrojů ÚHUL, které posloužila jako validační data z terénu potažmo trénovací množiny klasifikačním algoritmům. Poskytnutá vektorová data ve formátu shapefile, v rozsahu hranic přírodní lesní oblasti č. 7, obsahují informace o strukturovaném porostním typu (dále též SPT). SPT je dán výčtem skupin dřevin a charakterem smíšení. Polygonová vrstva tvoří nesouvislou plochu vektorových dat, která jsou charakterizována kódovým označením, charakterizujícím poměr zastoupení porostních typů.

Tabulka 1: Charakter smíšení (zdroj: ÚHUL, 2017)

	popis
Čisté (C)	jeden porostní typ se zastoupením 90–100 %
Smíšené (S)	dominantní (D) – jeden porostní typ se zastoupením 70–89,9 %
	majoritní (M) – jeden porostní typ se zastoupením 50–69,9 %
Nesourodé (N)	základní (Z) – jeden porostní typ se zastoupením 30–49,9 %
	přimíšené (P) – jeden porostní typ se zastoupením 10–29,9 %
Vtroušené (V)	skupiny dřevin se zastoupením do 10 % nejsou zpravidla uvažovány

V předkládané práci byla zpracována pouze data označená písmenem C, která dle Tabulky 1, charakterizuje jeden porostní typ se zastoupením 90–100 % na daném polygonu. Případné použití i dalších charakterů smíšení by mohlo vést v procesu klasifikace ke snížení odlišitelnosti zvolených SPT. Ostatní polygony, reprezentující další typy SPT a jejich smíšení, byly sloučeny do společné třídy ostatní porostní typy. Polygonová vrstva charakterizující SPT byla od ÚHUL získána v souřadnicovém systému S-TSK. Před samotnou volbou nejvhodnějších polygonů pro trénovací a kontrolní množiny byla zkontrolována topologická přesnost vektorového souboru v software ArcMap.

4.1.2 Stanovení klasifikačního systému

Pro práci bylo využito typologického klasifikačního systému, který používá Ústav pro hospodářskou úpravu lesů. Systém byl publikován v letech 1971, 1976 a doplněn v roce 1984 (Plíva, 1971, 1976, 1984). Mapovací jednotkou je varianta lesního typu v přírodní lesní oblasti. Definice lesního typu (ÚHÚL) je totožná se Zlatníkovou definicí lesního typu (1956): Lesní typ je soubor lesních biocenóz původních i změněných a jejich vývojových stadií včetně prostředí, tedy geobiocenóz vývojově k sobě patřících (Divíšek, Culek, Jiroušek, 2010).

V dokumentu s názvem Oblastní plány rozvoje lesů, který vydal ÚHÚL v roce 2001, je podrobně charakterizována dřevinná skladba na daném území. OPRL se zpracovávají pro jednotlivé přírodní lesní oblasti. Platnost každého oblastního plánu rozvoje lesů je 20 let. Z výsledků této studie bylo stanoveno 6 klasifikačních tříd, které odpovídají 6 stejným a zároveň nejrozšířenějším druhům lesního porostu na daných územích:

- a. Smrk ztepilý (třída č. 1),
 - Strom vysoký až 50 m s kuželovitou korunou, který původně roste v horských lesích, inverzních údolích, v rašeliništích a lokalitách s vyšší půdní vlhkostí. Lesnickým hospodařením byl rozšířen i do nižších poloh a na nepůvodní lokality, kde mnohdy vytváří rozsáhlé monokultury (Krása, 2007).
- b. Borovice lesní (třída č. 3),
 - Vyšší strom dorůstající kolem 40 m výšky a kolem 1 m v průměru kmene, který má mezi stromovitými dřevinami největší areál na světě. Dnes je pěstována na celém území ČR (mimo vyšší polohy) na ploše třikrát větší, než je její přirozený areál u nás (Krása, 2007).
- c. Modřín opadavý (třída č. 4),
 - Strom dorůstající výšky 20–50 m, který roste ve světlých lesích, na půdách hlubších, spíše bazických, čerstvých, ale ne vlhkých. U nás je původní pouze na východ od Hrubého Jeseníku, všechny ostatní výsadby modřínů jsou vesměs nepůvodní (Krása, 2007).
- d. Dub letní (třída č. 5),
 - Strom vysoký do 50 m, který je na území ČR rozšířený především v nížinách (tvrdé lužní lesy) a pahorkatinách. Jedná se o důležitou

lesnickou dřevinu nižších poloh a též okrasnou dřevinu (Krása, 2007).

- e. Buk lesní (třída č. 6),
 - Statný opadavý strom dorůstající 40–50 m výšky se štíhlým válcovitým kmenem a s kuželovitou, později rozložitě vyklenutou korunou, je jednou z hospodářsky nejdůležitějších listnatých dřevin Evropy a v ČR je rozšířen téměř po celém území (Krása, 2007).
- f. Bříza bělokorá (třída č. 9),
 - Strom dorůstající až 25 m výšky, který se využívá i k rekultivacím. U nás je rozšířen jak v lesích, tak v parcích a zahradách. Kvete od dubna do května (Krása, 2007).

Zmíněných 6 tříd lesního porostu bylo dále doplněno:

- g. Ostatní porostní typ (třída č. 0),
reprezentující další typy lesního porostu bez ohledu na jejich smíšení.
- h. Holiny (třída č. 11),
charakterizující plochy z nichž byl lesní porost odtěžen.

4.1.3 Rastrová data

4.1.3.1 Sentinel-2

Jedním z projektů Evropské kosmické agentury pro průzkum planety Země, je Copernicus (dříve GMES), jehož kosmickými komponenty jsou družice Sentinel 1–5. První tři řady družic tvoří dvojice, označované jako A a B, které jsou navrženy tak, aby svým časovým i prostorovým rozlišením vytvořily kvalitní základ pro služby Copernicus. „Po r. 2020 budou následovat i jednotky C a D stejných parametrů, které dosluhující družice postupně nahradí.“ (Cenia, 2016) Družice Sentinel-2 na své palubě nesou multispektrální senzor s vysokým rozlišením. Zkráceně nazýván MSI (Multispectral instrument) je první senzor svého druhu, který zahrnuje mimo jiné tři pásma v červeném okraji viditelného spektra a jeho data jsou tak svými parametry ideální také pro monitorování vegetace se zaměřením na klasifikaci lesních porostů, mapování obsahu chlorofylu v listech, sledování zdravotního stavu vegetace a tvorbu vegetačních indexů. V Tabulce 2 můžeme vidět, že čtyři pásma mají prostorové rozlišení 10 m, šest pásem rozlišení 20 m a tři pásma rozlišení 60 m. Družice druhé řady

se vyznačují nebývale širokým záběrem, který dosahuje až 290 km (Žubrietovský, Švábová, Šváb, 2017).

Tabulka 2: Spektrální pásma družice Sentinel-2 (zdroj: vlastní zpracování dat z Gisat). Tučně jsou zvýrazněna pásma použitá v této práci

Označení pásma	Rozsah od [μm]	Rozsah do [μm]	Kódování spektrálního pásma	Prostorové rozlišení [m]
2	0.4575	0.5225	BLUE	10.0
3	0.5425	0.5775	GREEN	10.0
4	0.65	0.68	RED	10.0
8	0.7845	0.8995	NIR	10.0
5	0.6978	0.7125	RED EDGE	20.0
6	0.7325	0.7475	NIR	20.0
7	0.773	0.793	NIR	20.0
8a	0.855	0.875	NIR	20.0
11	1.565	1.655	SWIR	20.0
12	2.1	2.28	SWIR	20.0
1	0.433	0.453	COASTAL	60.0
9	0.935	0.955	NIR	60.0
10	1.365	1.395	NIR	60.0

Předzpracovaná data Sentinel-2 jsou dostupná celkem ve třech úrovních (1B, 1C, 2A) a to ve formě dlaždic, což jsou nejmenší části snímku obsahující všechna spektrální pásma. Pro úroveň 1B má dlaždice rozměr 25 x 23 km a obsahuje atmosférickou korekci a korekci geometrie senzoru. Úrovně 1C a 2A jsou ortorektifikované snímky s plochou 100 km² v projekci UTM / WGS84. Systém UTM (Universal Transverse Mercator) rozděluje zemský povrch do 60 zón, z nichž každá má rozměry 6°x8°. Produkt Level-1C obsahuje masku vodních ploch, oblačnosti a ECMWF data. Jak úroveň 1B, tak úroveň 1C poskytují údaje o naměřených hodnotách odraženého záření na svrchní hranici skutečné atmosféry (TOA). Úroveň 2A, která je odvozená z úrovně 1C, poskytuje údaje na spodní hranici skutečné atmosféry (BOA) (Žubrietovský, Švábová, Šváb, 2017, 2017).

V předkládané práci byl zpracován satelitní snímek pro zájmové území, který byl pořízen 27. srpna 2016. Zvolen byl z důvodu minimálního rozsahu oblačnosti na snímku (téměř nulové), dále odpovídá požadavku na termín snímání ke konci vegetačního období rostlin a je možné nalézt snímek obdobných parametrů pořízený

družici Landsat 8. Jak lze vidět níže z kódového označení, jedná se o snímek Sentinel-2A, který obsahuje úroveň zpracování 1C.

- Kódové označení použitého snímku:
S2A_OPER_PRD_MSIL1C_PDMC_20160828T210754_R022_V20160827T101022_20160827T101025
- Informace o rozsahu oblačnosti: CLOUD_COVER = 0.02

4.1.3.2 Landsat 8

Program Landsat, který je řízený Národním úřadem pro letectví a kosmonautiku (NASA) a Národní geologickou službou Spojených států amerických (USGS), poskytuje již více než 40 let satelitní snímky celého zemského povrchu. Právě díky dlouhodobosti lze sestavit pro libovolnou oblast zemského povrchu časovou řadu v rozsahu i desítek let. Již v roce 1972 byla vypuštěna první družice Landsat 1, která společně s dalšími třemi, které byly vypuštěny v průběhu následujících 12 let, již není v provozu. V současné době snímají zemský povrch družice Landsat 5, 7 a 8 (Landsat 6 havarovala při startu). Nejnovější Landsat 8, který byl vynesena na oběžnou dráhu Země v roce 2013, nese na své palubě snímače OLI (Operational Land Imager) a TIRS (Thermal InfraRed Sensor). Jak lze v Tabulce 3 vidět, první zmíněné zařízení snímá zemský povrch v devíti pásmech viditelného a infračerveného spektra, přičemž šířka záběru dosahuje 185 km. Produkuje jak panchromatická (černobílá) data s prostorovým rozlišením 15 m, tak data barevná, která však mají prostorové rozlišení 30 m. Pro snímání termálního spektra slouží senzor TIRS, který snímá ve dvou pásmech s prostorovým rozlišením 100 m. Poskytovaná data jsou umístěna v 33. pásu souřadnicového systému UTM / WGS84. (LANDSAT 8 DATA USERS HANDBOOK, 2016).

Od roku 2016 jsou produkovaná data na úrovni Level 1 uspořádaná do 3 kategorií (tzv. tiered collection). U dat v první kategorii byly již provedeny atmosférické a radiometrické korekce, druhá kategorie obsahuje data bez těchto korekcí a poslední kategorie obsahuje real-time data uložená ihned po snímání. Snímky z družice Landsat 8 jsou zdarma ke stažení na webu USGS a součástí staženého souboru je dále také Quality Assessment (QA) snímek. Jedná se o 16bitovou masku, která je složena z pixelů oblačnosti (LANDSAT 8 DATA USERS HANDBOOK, 2016).

Tabulka 3: Spektrální pásma družice Landsat 8 (zdroj: vlastní zpracování dat z Gisat). Tučně jsou zvýrazněna použitá pásma v této práci

Označení pásma	Rozsah od [μm]	Rozsah do [μm]	Kódování spektrálního pásma	Prostorové rozlišení [m]
8 PAN	0.5	0.68	PAN	15.0
1	0.433	0.453	COASTAL	30.0
2	0.45	0.515	BLUE	30.0
3	0.525	0.6	GREEN	30.0
4	0.63	0.68	RED	30.0
5	0.845	0.885	NIR	30.0
9	1.363	1.384	CIRRUS	30.0
6	1.560	1.660	SWIR 1	30.0
7	2.107	2.294	SWIR 2	30.0
10	10.600	11.190	TIR	100.0
11	11.500	12.510	TIR	100.0


Další úroveň zpracování dat Landsat 8 je Level 2 SR, která poskytuje uživateli data již připravená k použití např. pro monitorování krajinného pokryvu. Jedná se o odhad spektrální odrazivosti povrchu, která by byla měřena na úrovni povrchu, tedy bez zásahu atmosférického rozptylu či absorpce energetických částic záření. Tento odhad je prováděn pomocí Landsat Surface Reflectance Code (LaSRC), který pracuje s pobřežním pásmem (coastal aerosol band) a klimatickými daty z družice MODIS (LANDSAT 8 DATA USERS HANDBOOK, 2016).

Pro účely této práce byl využit satelitní snímek, který byl pořízen ve stejný den, jako je tomu u snímku z družice Sentinel-2, tedy dne 27. srpna 2016. I v tomto případě se podařilo sehnat snímek s minimálním množstvím oblačnosti, která by pokrývala dané zájmové území, a odpovídající dalším požadavkům (vegetační období rostlin atd.). Kódové označení nese informaci o úrovni předzpracování L1TP, ve skutečnosti se však jedná o Level 2 SR, který je uživatelům poskytován na požádání.

- Kódové označení použitého snímku:
LC08_L1TP_192025_20160827_20170321_01_T1
- Informace o rozsahu oblačnosti: Cloud_Coverage_Assessment = 0.0

Na Obrázku 4 je názorně ukázáno odlišné prostorové rozlišení snímku pořízeného z obou zmiňovaných družic. Snímky jsou zobrazeny v nepravých barvách (pásma 5-4-3 pro Landsat 8 a pásma 8-4-3 pro Sentinel-2).

Obrázek 4: Porovnání prostorového rozlišení v nepravých barvách pro PLO 7. Vlevo Landsat 8 s 30m pixelem, vpravo Sentinel-2 s 20m pixelem (zdroj: vlastní zpracování)



4.2 Použitý software

ArcMap

Jedná se o jeden z nejpopulárnějších komerčních softwarů z řady ArcGIS, který byl vytvořen a je provozován, americkou firmou ESRI. Slouží pro zpracování mapových úloh včetně kartografie, prostorových analýz a editace dat. Poskytuje kompletní nabídku nástrojů pro práci s prostorovými daty (ARCDATA, 2018).

ENVI

Před třemi lety koupila korporace Harris Geospatial Solutions firmu Exelis, která vyvinula software ENVI. Ten vznikl především za účelem zpracování družicových

snímků, ale umožňuje také práci s radarovými nebo jinak nasnímanými daty dálkového průzkumu země. Hlavní předností je vizualizace velkého objemu dat, která je následně možné analyzovat speciálními nástroji, klasifikovat, detekovat jejich změny či dokonce vypočítat vegetační indexy apod. (Harris Geospatial Solutions, 2018).

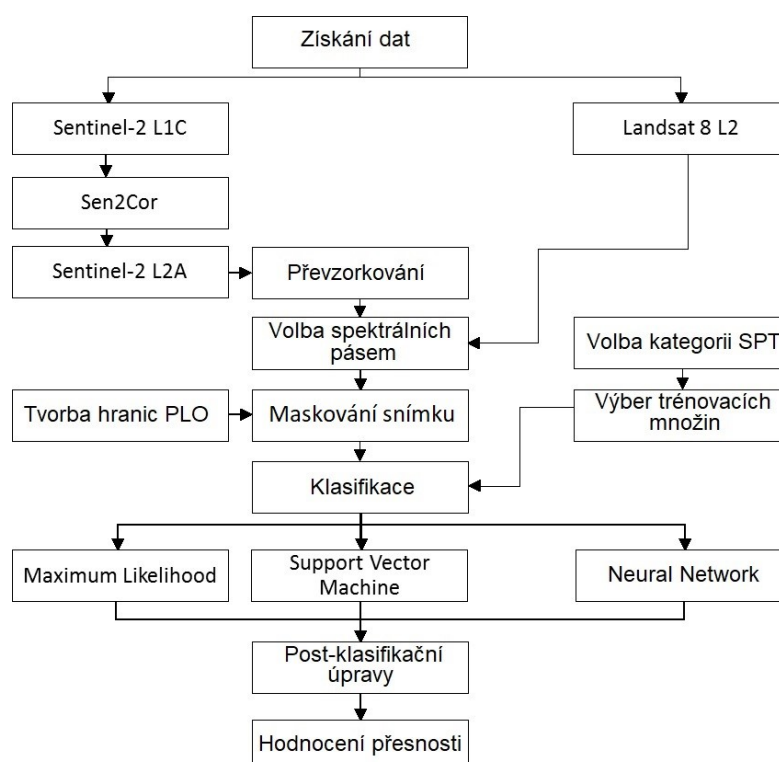
SNAP

Pro zpracování satelitních snímků Sentinel byl využit software doporučovaný a vytvořený samotnou Evropskou komisí. Volně dostupný balíček nástrojů slouží ke snadnému zobrazení RGB obrazu, jeho ortorektifikaci, reprojekci nebo také např. k tvorbě subsetu a jeho převzorkování. Správa, aktualizace a vývoj samotného software je zajištěn stále se rozrůstající komunitou uživatelů, kteří se pravidelně setkávají na STEP fóru (ESA, 2018).

4.3 Metodika

V předkládané práci bylo postupováno systematicky, jak je uvedeno na Obrázku 5. Od stažení obou družicových snímku, jejich předzpracování v doporučených softwarech, přes získání vektorových dat, následnou klasifikaci dle stanovených trénovacích množin, až k závěrečnému hodnocení přesnosti, které případně vedlo k poupravění vstupních dat za účelem zkvalitnění výsledných klasifikací.

Obrázek 5: Metodika práce (zdroj: vlastní zpracování)



4.3.1 Předzpracování satelitních snímků

V předchozí kapitole bylo zmíněno, jaké úrovně předzpracování byly aplikovány na zvolené snímky. Zatímco scéna Landsat 8 již obsahuje atmosférické korekce, a jedná se tedy o hodnoty odrazivosti na úrovni spodní atmosféry BOA, pro další práci s daty Sentinel-2 je nutné korekce teprve provést. Software SNAP umožňuje po nainstalování pluginu Sen2Cor vytvářet data na úrovni předzpracování 2A, tedy včetně atmosférických korekcí, lépe řečeno data na úrovni BOA. Dále byla odmaskována oblačnost, která navzdory nulovým hodnotám může být reprezentována vodní párou.

Satelitní snímky a jejich jednotlivá spektrální pásma, jak již bylo zmíněno v předchozí kapitole, mají odlišné prostorové rozlišení. Aby bylo možné vzájemné porovnání, bylo nutné před samotnou klasifikací provést převzorkování vybraných pásem u obou snímků. Zvolenou hodnotou prostorového rozlišení bylo 20 metrů pro Sentinel-2 a 30 metrů pro Landsat 8. Samotné převzorkování snímku z družice Sentinel-2 bylo provedeno v software SNAP, který umožňuje, po načtení .xml souboru obsahujícího metadata stažené scény, převzorkovat metodou nejbližšího souseda do 20 metrového rozlišení všechna pásma a následně vytvořit subset vybraných spektrálních pásem (viz tučně v Tabulce 2). Vzniklý rastr spojených spektrálních pásem v jeden soubor byl vyexportován pro další použití v práci do formátu .tiff.

Snímky Landsat 8 byly zpracovány pomocí funkce Composite Bands v software ArcMap, která spojí pásma z multispektrálního snímku v jeden rastrový dataset, obsahující zvolené spektrální informace (chceme-li pásma). Pro klasifikace v této práci byla zvolena pásma, kterou jsou tučně zvýrazněna v Tabulce 3 se shodným prostorovým rozlišením.

Pro urychlení procesu klasifikace, který je velmi náročný na výpočetní výkon počítače, byly zvolené snímky oříznuty dle hranic PLO. Jelikož se předkládaná práce zabývá klasifikací druhové skladby lesa, byla na oba připravené a oříznuté snímky aplikována maska. Klasifikací pod maskou by tudíž měl být rozptýl hodnot, které vstoupí do procesu klasifikace, omezen pouze pro lesní porosty. Jako zdroj dat pro masku klasifikovaného území byla využita polygonová vrstva od ÚHUL. Pomocí funkce Dissolve byla v software ArcMap tato vrstva sloučena v jeden ohraničující polygon, který tvořil polygonovou vrstvu pouze nad zalesněným územím. Následně bylo využito

v software ENVI funkce Apply Mask, která přiřadila hodnotu NoData území, které bylo mimo hranice zalesněného území.

4.3.2 Trénovací množiny

Pro další práci s vektorovými daty ÚHUL, která obsahují informaci o výskytu určitého lesního typu na území zvoleného polygonu, bylo potřeba provést sjednocení některých kategorií tak, aby počet tříd odpovídal počtu a typu stanovenému pro zvolená zájmová území.

Před samotnou volbou nejvhodnějšího souboru množin, byla stanovena nejnižší hodnota plochy polygonu, který může v souboru množin zastupovat zvolenou třídu. Vzhledem k prostorovému rozlišení použitých snímků ke klasifikaci byla hodnota 1 pixelu. Pro Sentinel-2 hodnota odpovídá zvolenému prostorovému rozlišení 20 metrů (nejmenší polygon = 400 m²), pro scénu Landsat 8 tedy 30 m (nejmenší polygon = 900 m²). Hodnota byla inspirována diplomovou prací Oubrechtové (2012), která při zpracování satelitního snímku SPOT 5 za účelem klasifikace land coveru pracovala taktéž s hodnotou 1 pixelu. Urban Atlas (2016) pracuje s hodnotou 2500 m², která by však při použití v předkládané práci mohla snížit potenciál využití zpracovávané podrobné klasifikace typů lesního porostu. Dále také hodnotu 1 pixelu využila Šmausová (2016) ve své diplomové práci, která se zabývá využitím multispektrálních družicových dat pro klasifikaci lesních porostů poškozených disturbancemi.

Vzhledem k přirozenému přechodu lesních porostů v přírodě, který není možné charakterizovat ostrou hranicí, ale spíše pásmem přechodového stadia, byl za účelem minimalizace následku mísení okolních typů lesního porostu do hodnoty, nesoucí daný polygon vektorové vrstvy, proveden Buffer s parametrem outside-only -10 m pro každý polygon vektorové vrstvy. Tím byly odfiltrovány hraniční oblasti o šířce 10 metrů z obou sousedících polygonů.

Nejdříve bylo nutné rozklíčovat kódové označení SPT, které je dáno výčtem skupin dřevin a charakterem jejich smíšení. Vzhledem k poskytnutému dokumentu od ÚHUL, který obsahuje podrobný popis jednotlivých porostních typů a popis charakteru smíšení, bylo pomocí funkce Select by Attributes vytvořeno 6 tříd lesního porostu.

Dále bylo třeba vybrat nejvhodnější soubor trénovacích množin z původního souboru 62 357 polygonů. Nejdříve byla v atributové tabulce vypočtena rozloha všech polygonů. Funkcí Select by Attributes byly vybrány polygony menší než stanovená hodnota nejmenšího pixelu a následně odstraněny z datového souboru. Pro nejrozšířenější kategorie s velkým počtem polygonů, byly odstraněny obrovské polygony v řádech stovek tisíc metrů čtverečních, které by mohly obsahovat nechtěné přimísení dalších typů krajinného pokryvu. Následovala podrobná kontrola polygonů nad družicovými snímky v kombinaci spektrálních pásem v nepravých barvách (viz Obrázek 4), která umožňuje lepší rozlišení typů lesního porostu. Touto kontrolou bylo zjištěno, že nejtmavším odstínem červené, téměř černé barvy, jsou reprezentovány jehličnany. Naopak listnaté SPT je možné charakterizovat světlejšími odstíny červené. Dále syntéza odlišuje odstíny fialové barvy výšku porostu, kdy mladé nízké stromy jsou odlišeny světle fialovou, téměř růžovou, a vysoké staré stromy dosahují tmavě fialových barev, téměř černé. Právě v těchto specifických případech různého stáří, hustoty a zdraví porostu bylo využito za účelem zpřesnění hranice polygonu dané třídy, ortofota od INSPIRE, které má rozlišení 10 m.

Obrázek 6: Špatně zařazená třída č. 9 bříza bělokorá (zdroj: vlastní zpracování ortofota INSPIRE)



Na Obrázku 6 lze vidět problematickou oblast, kterou při sběru dat označili pracovníci ÚHUL za břízu (třída č. 9). Je možné, že od roku 2016 do roku 2017, tedy rozdíl v letech sběru dat pro polygonovou vrstvu ÚHUL a snímání pro ortofoto INSPIRE,

bylo území vykáceno, ale je to příklad problematické volby trénovacích množin pro třídy strukturovaného porostního typu. Na Obrázku 7 je znázorněn další příklad chybně zařazeného polygonu, který by dle dat ÚHUL měl popisovat borovici (třída č. 3). Uvedené příklady pouze ilustrují různorodou kvalitu definice SPT pro polygonovou vrstvu, která byla základním zdrojem pro výběr trénovacích množin v předkládané práci.

Obrázek 7: Špatně zařazená třída č. 3 borovice lesní (zdroj: vlastní zpracování ortofota INSPIRE)



Výsledkem výše uvedeného postupu byl vybrán soubor nejvhodnějších trénovacích množin. Charakteristiku trénovacích množin lze vidět v Tabulce 4.

Tabulka 4: Charakteristika trénovacích množin. Zkratky tříd: č. 0 = ostatní porostní typ, č. 1 = smrk ztepilý, č. 3 = borovice lesní, č. 4 = modřín opadavý, č. 5 = dub letní, č. 6 = buk lesní, č. 9 = bříza bělokorá, č. 11 = holiny. Uvedená velikost a rozloha je ve čtverečních metrech (zdroj: vlastní zpracování)

třída	min. vel. polygonu	max. vel. polygonu	rozloha	počet polygonů	počet pixelů S2	počet pixelů L8
0	1 775	42 962	828 661	207	2 072	921
1	1 479	63 427	1 005 705	176	2 514	1 117
3	366	73 700	876 915	185	2 192	974
4	409	7 834	99 029	40	248	110
5	397	47 675	285 925	91	715	318
6	401	123 114	456 422	76	1 141	507
9	614	8 785	32 750	11	82	36
11	2 438	29 286	250 095	21	625	278

Nemalá část přípravy trénovacích množin byla věnována co nejlepší odlišitelnosti zvolených tříd SPT. Ta byla sledována na hodnotách separability skrze transformovanou odchylku (Transformed Divergence), což odpovídá vážené vzdálenosti mezi průměrnými vektory uvažovaných tříd. Software ENVI umožňuje analyzovat trénovací množiny funkcí Compute ROI Separability. Hodnoty divergence se pohybují v rozmezí od 0 do 2, kdy 0 značí naprostou shodu a 2 naopak vysokou míru odlišnosti mezi třídami. Optimální hodnoty divergence by se měly mezi různými třídami pohybovat v intervalu od 1,9 do 2. Obecně však platí čím větší je divergence, tím větší je statistická vzdálenost mezi trénovacími plochami, a tím je větší pravděpodobnost správné klasifikace tříd (Dobrovolný, 1998).

Tabulka 5: Matice divergencí trénovacích množin pro Sentinel-2. Zkratky tříd: č. 0 = ostatní porostní typ, č. 1 = smrk ztepilý, č. 3 = borovice lesní, č. 4 = modřín opadavý, č. 5 = dub letní, č. 6 = buk lesní, č. 9 = bříza bělokorá, č. 11 = holiny (zdroj: vlastní zpracování)

třída	0	1	3	4	5	6	9	11
0	x	x	x	x	x	x	x	x
1	0,7186	x	x	x	x	x	x	x
3	0,6184	0,7409	x	x	x	x	x	x
4	0,5906	0,8804	0,6651	x	x	x	x	x
5	1,1929	1,8996	1,7450	1,5780	x	x	x	x
6	1,3613	1,9164	1,8416	1,5913	0,7833	x	x	x
9	0,9785	1,6669	1,5866	1,2501	1,0976	0,7581	x	x
11	1,9711	1,9803	1,9769	1,9475	1,9853	1,9503	1,9695	x

Hodnoty divergencí trénovacích množin, vybraných pro zpracování snímku Sentinel-2, jsou znázorněny v Tabulce 5. Jak lze vidět, doporučených hodnot divergence dosahuje pouze třída č. 11 holiny, pro kterou byly trénovací množiny sbírány na základě ortofota. Dále je možné si povšimnout vyšších hodnot odlišitelnosti třídy č. 1 smrk, tříd č. 5 dub a č. 6 buk, reprezentujících listnaté porostní typy. Separabilita v případě těchto tříd dosahuje hodnot okolo 1,9, což téměř odpovídá požadavku na optimální hodnoty divergence. Potvrzuje to předpoklad jednoduššího rozlišení jehličnatých od listnatých stromů oproti možnosti rozlišit jednotlivé typy jehličnatých či listnatých lesních porostů mezi sebou.

Využití stejného souboru trénovacích množin pro zpracování snímku Landsat 8, který má odlišné spektrální rozlišení, mělo za následek snížení hodnot divergencí u téměř všech tříd SPT. Rozdílné jsou také hodnoty divergencí třídy č. 9 bříza, které vůči třídám č. 0 ostatní PT, č. 1 smrk a č. 6 buk lesní dosahují vyšší separability,

než je tomu u trénovacích množin pro Sentinel-2. Počet pixelů, které reprezentují zmiňovanou třídu SPT je výrazně nižší než u ostatních tříd, což může mít za následek rozdílné hodnoty divergencí. Dobrých hodnot divergence dosahuje třída č. 1 smrk vůči třídám listnatého PT. Třída č. 11 holiny, která byla vytvořena nad ortofotem, jak již bylo zmiňováno, vykazuje nejvyšší hodnoty divergencí, lze tedy předpokládat, že bude nejlépe odlišitelná od ostatních typů PT.

Tabulka 6: Matice divergencí trénovacích množin pro Landsat 8. Zkratky tříd: č. 0 = ostatní porostní typ, č. 1 = smrk ztepilý, č. 3 = borovice lesní, č. 4 = modřín opadavý, č. 5 = dub letní, č. 6 = buk lesní, č. 9 = bříza bělokorá, č. 11 = holiny (zdroj: vlastní zpracování)


třída	0	1	3	4	5	6	9	11
0	x	x	x	x	x	x	x	x
1	0,4912	x	x	x	x	x	x	x
3	0,4019	0,4355	x	x	x	x	x	x
4	0,4773	0,6085	0,6073	x	x	x	x	x
5	0,8528	1,5432	1,4438	1,2079	x	x	x	x
6	1,1695	1,6048	1,5806	1,2666	0,8792	x	x	x
9	1,1714	1,6292	1,5835	1,3133	0,7657	1,2568	x	x
11	1,7699	1,8384	1,8101	1,6674	1,7851	1,8333	1,4378	x

Nově vzniklý dataset s trénovacími množinami byl vyexportován do shapefile, který byl následně funkcí software Arcmap s názvem Project transformován do souřadnicového systému. S ohledem na nařízení vlády č. 430/2006 Sb. v platném znění byl zvolen souřadnicový systém Mercatorovo válcového konformního zobrazení (ČUZK, 2018), ve kterém jsou poskytovány satelitní snímky Sentinel-2 a Landsat 8. Dále byla prověřena polohová přesnost významných bodů, kterými jsou např. křižovatky silnic, vodní plochy apod. Jelikož poloha množin nevykazovala vysoké odchylky, nebylo nutné provést žádné geometrické korekce.


4.3.3 Použité klasifikační algoritmy

Klasifikace předzpracovaných satelitních snímků byla provedena v software ENVI 5.1. Jedním z faktorů, který může ovlivnit výslednou přesnost klasifikace, je volba spektrálních pásem na základě výsledků korelačních diagramů zvolené trénovací množiny. Jak lze na Obrázku 8 a 9 vidět, tak jak v případě dat Sentinel-2, tak Landsat 8, jsou hodnoty zastoupeny ve všech spektrálních pásmech obou zmiňovaných družicových snímků v připraveném subsetu ke klasifikaci (viz kapitola 4.3.1.).

Obrázek 8: Korelační diagram pro Sentinel-2. Zkratky tříd: č. 0 = ostatní porostní typ, č. 1 = smrk ztepilý, č. 3 = borovice lesní, č. 4 = modřín opadavý, č. 5 = dub letní, č. 6 = buk lesní, č. 9 = bříza bělokorá, č. 11 = holiny (zdroj: vlastní zpracování v ENVI)



Obrázek 9: Korelační diagram pro Landsat 8. Zkratky tříd: č. 0 = ostatní porostní typ, č. 1 = smrk ztepilý, č. 3 = borovice lesní, č. 4 = modřín opadavý, č. 5 = dub letní, č. 6 = buk lesní, č. 9 = bříza bělokorá, č. 11 = holiny (zdroj: vlastní zpracování v ENVI)



Maximum Likelihood

Samotné klasifikace předcházela volba všech spektrálních pásem v připraveném subsetu, která vstoupila do klasifikace. Následně byly zvoleny všechny kategorie nasbíraných trénovacích množin a zvolena prahová hodnota None. Pro nastavení parametru Data Scale Factor, bylo nutné nahlédnout do metadat obou snímků. Bylo zjištěno, že bitová hloubka je 16bit, což odpovídá hodnotě $2^{16} = 65\,536$. Po uložení výsledku první klasifikace byl proces proveden se stejným nastavením parametrů taktéž pro snímek Landsat 8.

Support Vector Machine

Proces klasifikace pomocí podpůrných vektorů, jak lze název volně přeložit, byl taktéž na vstupu definován všemi spektrálními pásmy připraveného subsetu v předchozí kapitole předkládané práce. Po výběru všech osmi kategorií trénovacích množin bylo přistoupeno k volbě parametrů, které mohou mít přímý vliv na kvalitu výsledku klasifikace. Inspirací zde byla diplomová práce Hromádkové (2015), která dospěla k výsledku, že k nejvyšším hodnotám klasifikační přesnosti dochází při použití polynomicke jádrové transformace 6. stupně (dále též SVM – Poly6). Dále uvádí, že nejpresnějších výsledků dosahoval klasifikátor SVM při použití chybového parametru pro hodnotu 100. V práci s názvem A Comparison of Support Vector Machine and Decision Tree Classifications Using Satellite Data of Langkawi Island z roku 2009 porovnávají autoři Shafri a Ramle jádrové transformace s různě nastavenými parametry. Jedním z výstupů je mimo jiné konstatování, že nejvyšších hodnot přesnosti klasifikace dosahuje radiální bázová funkce jádrové transformace (dále též SVM – RBF).

Dva typy jádrové transformace, které byly zmíněny v předchozím odstavci, včetně zmiňovaného chybového parametru, byly použity při klasifikačním procesu v předkládané práci. Prahová hodnota algoritmu byla ponechána na původní hodnotě nula. Popsaný postup byl aplikován na oba typy vstupních rastrových dat.

Neural Network

Algoritmus ze skupiny řízené klasifikace, s názvem neuronové sítě, byl aplikován na všechna spektrální pásma satelitních snímků, která vstoupila do klasifikačního procesu. Nejprve bylo zvoleno všech osm kategorií trénovacích množin a poté bylo možné již přistoupit k nastavení samotných parametrů, které mohou přímo ovlivnit výslednou přesnost tohoto klasifikátoru. Prvním způsobem klasifikování snímků bylo ponechání původních přednastavených hodnot $TTC = 0,9$, $TR = 0,2$ a počet iterací = 1000 (dále též NN – Def). Dalšími možnostmi nastavení parametrů algoritmu se zabývala Hromádková (2015), která dospěla k závěru, že ideálním výsledkem přesnosti klasifikace s ohledem na výpočetní výkon stroje, na kterém jsou klasifikace prováděny, je počet iterací = 3000, $TR = 0,1$ a $TTC = 0,4$ (dále též NN – Mod 1). Nastavením klasifikátoru NN se zabývala ve své diplomové práci také Oubrechtová (2012), která v závěru uvádí, že pro zpracování dat SPOT 5,

dosahuje nejlepších přesností nastavení: $TTC = 0,2$; $TR = 0,2$; $TM = 0,4$ (dále též NN – Mod 2). Nejvhodnějším nastavením parametrů NN za účelem maximalizace přesnosti výsledné klasifikace snímků družice Landsat 8 se zabývala např. i Šmausová (2016), která za ideální hodnoty označila: $TTC = 0,1$, $TR = 0,2$, $TM = 0,5$, počet iterací = 1000 (dále též NN – Mod 3). Klasifikací s těmito parametry dosáhla celkové přesnosti 69,61 % u L8 a 81,65 % u multispektrálního snímku družice vysokého rozlišení WorldView-2.

Za účelem porovnání výkonu a přesnosti klasifikačního algoritmu neuronových sítí, byly v předkládané práci provedeny výpočty s výše uvedenými parametry pro oba zpracovávané snímky z družic Sentinel-2 a Landsat 8.

4.3.4 Přesnost klasifikace

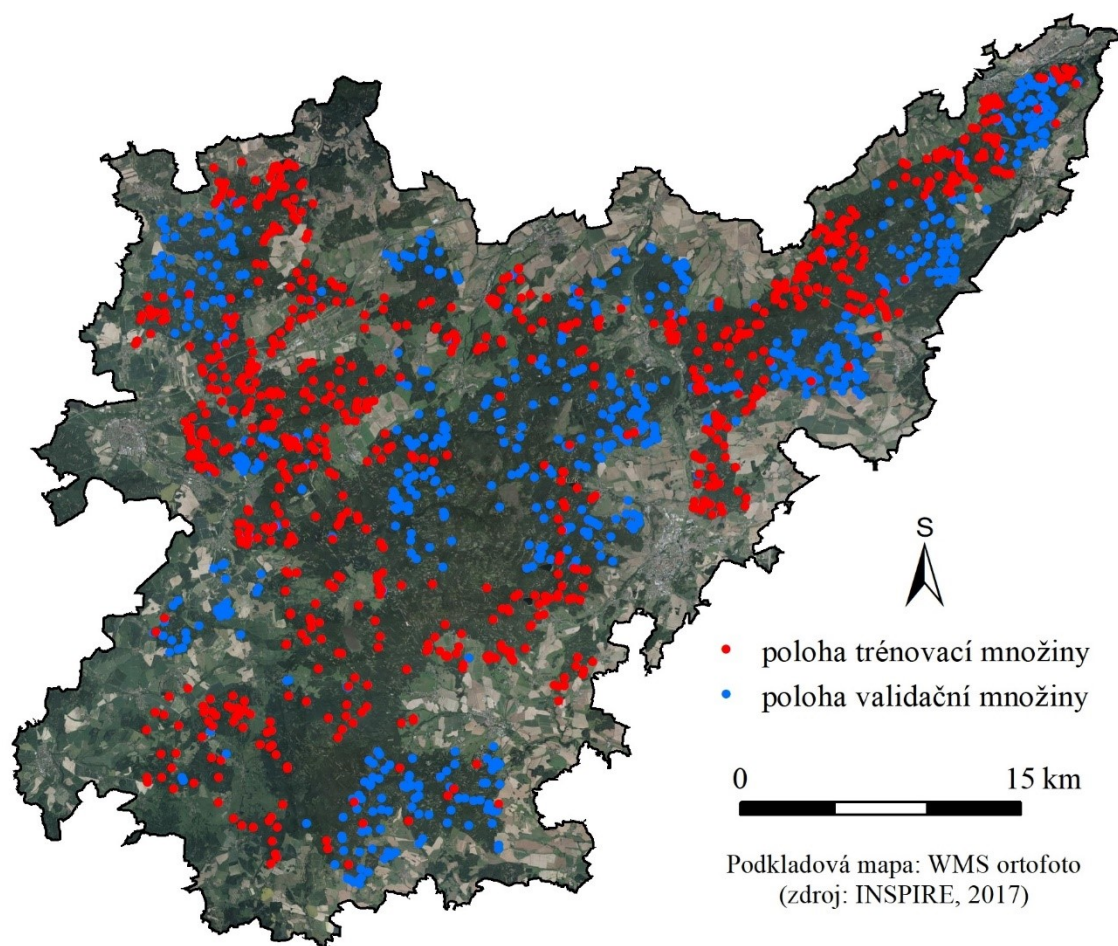
Než bylo možné provést hodnocení přesnosti, bylo na výsledky klasifikačních procesů použito několik post klasifikačních úprav. Obě dvě následující úpravy byly provedeny v software ENVI, který umožňuje sadou nástrojů zpracovat výsledek ihned po dokončení klasifikace. Nejdříve byla aplikována funkce Sieve, která odebere izolované pixely tak, že porovná hodnotu s okolními 4 pixely. Je-li počet pixelů třídy, které tvoří shluk, menší než zadaná hodnota, jsou tyto pixely odebrány z klasifikované třídy. Jsou-li pixely odebrány metodou prosévání, jak by bylo možné přeložit název z angličtiny, zůstanou po nich černé pixely (neklasifikované). Již v samotném popisu dané metody prosévání je doporučeno aplikovat následně další metodu, která shlukuje stejně klasifikované plochy pomocí morfologických operátorů. V popisu metody Clump Classes je dále uvedeno, že klasifikované snímky často trpí nedostatkem prostorové koherence (speckle nebo díry v klasifikovaných plochách). Vhodným nastavením velikosti operátoru, která byla v předkládané práci zvolena 3x3 pixely, lze odstranit zmiňované nedostatky (Harris Geospatial Solutions, 2018).

Aby bylo možné hodnotit přesnost klasifikace, je nutné získat kontrolní množiny. V předkládané práci bylo opět využito polygonové vrstvy od ÚHUL. Postupem uvedeným v kapitole č. 4.3.2 byl vybrán soubor nejvhodnějších polygonů. Z něho byla část odebrána pro vytvoření kontrolních množin. Jak lze v Tabulce 7 vidět, snahou autora bylo vybrat soubor kontrolních množin, který svým počtem polygonů bude odpovídat počtu polygonů trénovacích množin. Rozmístění trénovacích a kontrolních množin lze vidět na Obrázku 10.

Tabulka 7: Charakteristika kontrolních množin. Zkratky tříd: č. 0 = ostatní porostní typ, č. 1 = smrk ztepilý, č. 3 = borovice lesní, č. 4 = modřín opadavý, č. 5 = dub letní, č. 6 = buk lesní, č. 9 = bříza bělokorá, č. 11 = holiny (zdroj: vlastní zpracování)

třída	min. vel. polygonu	max. vel. polygonu	rozloha	počet polygonů	počet pixelů S2	počet pixelů L8
0	3 600	19 962	753 483	178	1 884	837
1	3 604	79 269	992 975	143	2 482	1103
3	422	43 432	668 196	149	1 670	742
4	510	15 866	47 928	20	120	53
5	410	49 112	328 115	77	820	365
6	426	25 907	241 683	79	604	269
9	824	56 546	98 035	11	245	109
11	2 957	19 758	167 863	19	420	187

Obrázek 10: Poloha trénovacích a kontrolních množin na území PLO 7 (zdroj: vlastní zpracování dat ArcČR 3.3.)



Jelikož předkládaná práce klade důraz na klasifikaci druhové skladby lesních porostů, bylo nedílnou součástí přípravy souboru kontrolních bodů pro hodnocení přesnosti klasifikace, stejně jako v případě souboru trénovacích množin, hodnocení odlišitelnosti jednotlivých klasifikovaných tříd SPT mezi sebou pomocí divergence. Jak lze v Tabulce 8 vidět, tak i v tomto souboru množin dosahuje nejvyšších hodnot odlišitelnosti třída č. 11 holiny, která, jak již bylo zmíněno, byla vytvořena na základě ortofota od INSPIRE s prostorovým rozlišením 10 metrů. Soubor kontrolních množin taktéž obsahuje polygony třídy č. 1 smrk, které lze optimálně odlišit od listnaté třídy č. 5 dub.

Tabulka 8: Matice divergencí kontrolních množin pro Sentinel-2. Zkratky tříd: č. 0 = ostatní porostní typ, č. 1 = smrk ztepilý, č. 3 = borovice lesní, č. 4 = modřín opadavý, č. 5 = dub letní, č. 6 = buk lesní, č. 9 = bříza bělokorá, č. 11 = holiny (zdroj: vlastní zpracování)

třída	0	1	3	4	5	6	9	11
0	x	x	x	x	x	x	x	x
1	0,8308	x	x	x	x	x	x	x
3	0,6559	0,9709	x	x	x	x	x	x
4	0,7574	1,1838	0,9057	x	x	x	x	x
5	1,2994	1,9362	1,7926	1,7074	x	x	x	x
6	0,9966	1,7227	1,5865	1,4799	0,9465	x	x	x
9	1,2898	1,7452	1,6984	1,4963	1,3940	0,7772	x	x
11	1,9611	1,9578	1,9680	1,9536	1,9936	1,9610	1,9316	x

Pro hodnocení přesnosti klasifikace snímku Landsat 8 byl využit stejný soubor kontrolních množin, jako v předchozím případě pro data Sentinel-2. I zde je patrný rozdíl divergencí v závislosti na prostorovém rozlišení zpracovávaných snímků. Pixel o velikosti 30 metrů pro Landsat 8 má nejspíše za následek drobné mísení s okolními typy lesního porostu, než které jsou definovány pro polygony od ÚHUL. Z Tabulky 9 lze zjistit, že téměř optimálních hodnot divergence dosahuje v souboru kontrolních množin třída č. 5 dub vůči třídě č. 11 holiny. Nízkých hodnot separability, necelých 1,2, dosáhla třída č. 11 holiny pouze vůči třídě č. 9 bříza, což může být způsobeno, stejně jako v případě trénovacích množin, malým počtem polygonů, které bylo možné zvolit jako nejvhodnější soubor množin pro zvolené třídy. Dále si lze povšimnout obdobných hodnot pro odlišení jehličnatých od listnatých SPT.

Tabulka 9: Matice divergencí kontrolních množin pro Landsat 8. Zkratky tříd: č. 0 = ostatní porostní typ, č. 1 = smrk ztepilý, č. 3 = borovice lesní, č. 4 = modřín opadavý, č. 5 = dub letní, č. 6 = buk lesní, č. 9 = bříza bělokorá, č. 11 = holiny (zdroj: vlastní zpracování)

třída	0	1	3	4	5	6	9	11
0	x	x	x	x	x	x	x	x
1	0,5282	x	x	x	x	x	x	x
3	0,5531	0,8204	x	x	x	x	x	x
4	0,7190	0,9457	0,7622	x	x	x	x	x
5	0,9569	1,6728	1,5154	1,4244	x	x	x	x
6	0,8024	1,4363	1,4368	1,2922	0,5663	x	x	x
9	1,4473	1,7072	1,7787	1,7499	1,3040	1,2074	x	x
11	1,7037	1,7264	1,7699	1,8297	1,8792	1,7702	1,1933	x

Následně byla na upravený klasifikovaný snímek aplikována funkce Confusion Matrix Using Ground Truth ROIs, která na základě výsledku klasifikace a k němu přiřazených kontrolních množin, vytvoří chybovou matici. Ta obsahuje dle Harris Geospatil Solutions (2018) několik ukazatelů přesnosti.

- Celková přesnost (overall accuracy dále též OA) = poměr celkového počtu správně klasifikovaných pixelů a celkového počtu klasifikovaných pixelů
- Chyby z opomenutí (Omission error dále též OE) = pixely dané třídy klasifikované do jiné třídy
- Chyby z nesprávného zařazení (Comission error dále též CE) = pixely jiné třídy klasifikované do dané třídy
- Zpracovatelský přesnost (producer accuracy dále též PA) = poměr správně klasifikovaných pixelů a skutečného počtu pixelů dané třídy z kontrolních bodů
- Uživatelská přesnost (user accuracy dále též UA) = pravděpodobnost s jakou pixel zařazený do určité třídy danou třídu ve skutečnosti reprezentuje
- Kappa koeficient (Kappa Coefficient) = poměr výsledné klasifikace a procesu náhodného zařazování pixelů k daným třídám, hodnota 1 představuje absolutní shodu, zatímco hodnota 0 nepředstavuje žádnou shodu

5 VÝSLEDKY

Nedílnou součástí každé diplomové práce jsou výsledky, které jsou vytvářeny na základě podrobně popsané metodiky. V předkládané práci byla provedena řízená klasifikace multispektrálních snímků z družic Sentinel-2 a Landsat 8. Té předcházela volba nejvhodnějšího souboru jak trénovacích, tak kontrolních množin. Zmiňované soubory množin byly vybrány na základě selekce s ohledem na velikost polygonů ve zvolených třídách pro klasifikaci a ty následně byly také podrobeny analýze separability. Zdrojem dat pro soubor množin byla na žádost získaná polygonová vrstva z Informačního a datového centra ÚHUL. Post klasifikační procesy, které vedly k odstranění možných nedostatků a následné hodnocení přesnosti (viz kapitola 4.3.4.) dávají možnost porovnat jak samotné zvolené klasifikační algoritmy, tak jejich podrobnější nastavení parametrů. V následující kapitole jsou popsány výsledné hodnoty klasifikací, které jsou pro názornější a snazší orientaci doplněny o grafy či tabulky.

5.1 Porovnání přesnosti řízených klasifikací satelitních snímků


Ke zhodnocení přesnosti aplikovaných klasifikačních algoritmů, které pracovaly s více než 800 polygony na vstupu v podobě trénovacích množin, byl využit software ENVI, kterým lze vytvořit chybovou matici. Ta porovná soubor kontrolních množin, kterých bylo vybráno více než 670, jedná se tedy o téměř shodný počet se souborem trénovacích množin, a následně vypočte celkovou přesnost a kappa koeficient.

Tabulka 10: Porovnání celkové přesnosti (OA) a kappa indexu. Zkratky: ML = Maximum Likelihood; SVM – RBF = Support Vector Machine s radiální bázovou funkcí jádrové transformace; SVM – Poly6 = Support Vector Machine s polynomickou funkcí jádrové transformace 6. stupně; NN – Def = Neural Network s původními parametry; NN – Mod 1 = TTC = 0.4, TR = 0.1 a počet iterací = 3000; NN – Mod 2 = TTC = 0.2, TR = 0.2 a TM = 0.4; NN – Mod 3 = TTC = 0.1, TR = 0.2, TM = 0.5 a počet iterací = 1000; S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)

		S2	L8		S2	L8
ML	OA	55,0044	49,0495	kappa	0,4590	0,3858
SVM – RBF	OA	60,5730	49,2121	kappa	0,5011	0,3528
SVM – Poly6	OA	61,2544	49,3997	kappa	0,5099	0,3564
NN – Def	OA	61,6281	38,4192	kappa	0,5158	0,2527
NN – Mod 1	OA	62,6246	53,4017	kappa	0,5283	0,4121
NN – Mod 2	OA	60,7415	41,9835	kappa	0,5068	0,2828
NN – Mod 3	OA	60,4924	42,4462	kappa	0,5027	0,2873

Dosažené hodnoty celkových přesností, které jsou znázorněny v Tabulce 10, se pohybují v rozmezí 55–63 % u klasifikace snímku Sentinel-2 a hodnot 38–53 % přesnosti klasifikace dat Landsat 8. Nejvyšší celkové přesnosti bylo dosaženo užitím algoritmu Neural Network s první modifikací. Pro data Landsat 8 zmíněný algoritmus dosáhl nejvyšší hodnoty celkové přesnosti 53,40 % a pro data Sentinel-2 62,63 %, což je o téměř 9 % více. Nejnižší hodnoty celkové přesnosti 55 % dosáhl, v případě zpracování snímku Sentinel-2, algoritmus Maximum Likelihood. Zpracováním druhého snímku, tedy z družice Landsat 8, dosáhl nejnižších hodnot přesnosti 38,42 % algoritmus Neural Network s původně přednastavenými parametry. Bylo dosaženo průměrné celkové přesnosti 60,33 % pro Sentinel-2 a 46,27 % pro Landsat 8.

Graf 1: Porovnání celkové přesnosti (OA) klasifikačních algoritmů. Zkratky: ML = Maximum Likelihood; SVM – RBF = Support Vector Machine s radiální bázovou funkcí jádrové transformace; SVM – Poly6 = Support Vector Machine s polynomickou funkcí jádrové transformace 6. stupně; NN – Def = Neural Network s původními parametry; NN – Mod 1 = TTC = 0.4, TR = 0.1 a počet iterací = 3000; NN – Mod 2 = TTC = 0.2, TR = 0.2 a TM = 0.4; NN – Mod 3 = TTC = 0.1, TR = 0.2, TM = 0.5 a počet iterací = 1000; S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)



Pro názornější ilustraci přesnosti výsledků klasifikace byla data zobrazena v Grafu 1. Lze si povšimnout největšího rozdílu mezi přesnostmi u algoritmu Neural Network DEF, který dosahuje hodnoty více než 23 % procent. Oproti tomu

nejmenšího rozdílu přesnosti při klasifikaci dat, s odlišným prostorovým rozlišením, dosáhl algoritmus Maximum Likelihood.

V následujících dvou tabulkách, jsou podrobně rozepsány rozlohy klasifikovaných tříd lesního porostu tak, jak je vytvořily použité algoritmy. Kategorie, do které byly zařazeny neklasifikované pixely, byla odstraněna. Kompletní kontingenční tabulky jsou přílohami této práce.

Tabulka 11: Rozloha klasifikovaných tříd z dat Sentinel-2. Zkratky: ML = Maximum Likelihood; SVM – RBF = Support Vector Machine s radiální bázovou funkcí jádrové transformace; SVM – Poly6 = Support Vector Machine s polynomickou funkcí jádrové transformace 6. stupně; NN – Def = Neural Network s původními parametry; NN – Mod 1 = TTC = 0.4, TR = 0.1 a počet iterací = 3000; NN – Mod 2 = TTC = 0.2, TR = 0.2 a TM = 0.4; NN – Mod 3 = TTC = 0.1, TR = 0.2, TM = 0.5 a počet iterací = 1000; S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)

	ML	SVM – RBF	SVM – Poly 6	NN – Default	NN – Mod1	NN – Mod2	NN – Mod3
třída	rozloha (%)	rozloha (%)	rozloha (%)	rozloha (%)	rozloha (%)	rozloha (%)	rozloha (%)
ostatní porostní typ	6,30	15,38	15,87	22,67	14,33	14,91	14,42
smrk ztepilý	40,99	41,51	41,98	42,46	46,52	43,60	43,52
borovice lesní	12,92	29,65	28,93	18,82	23,18	25,00	25,65
modřín opadavý	10,91	0,00	0,12	1,90	1,28	0,85	0,89
dub letní	4,28	2,28	2,51	1,70	3,89	1,55	1,43
buk lesní	3,66	6,18	5,34	6,73	3,83	7,58	8,49
bříza bělokorá	4,89	0,00	0,00	0,00	0,00	0,00	0,00
holiny	8,72	3,40	3,46	3,55	4,25	4,27	3,53

Použitím algoritmu Maximum Likelihood bylo klasifikováno z dat Sentinel-2 nejvíce pixelů do třídy č. 1 smrk ztepilý. Druhou největší třídou, jak lze v Tabulce 11 vidět, je č. 4 borovice lesní. Obdobný počet pixelů byl klasifikován pro všechny tři třídy listnatého lesního porostu. Odlišné rozlohy zmiňovaných tříd bylo dosaženo použitím všech dalších algoritmů. Klasifikátor Support Vector Machine, v obou variantách jádrové transformace, přiřadil téměř totožný počet pixelů klasifikovaným třídám. Menší rozdíly v rozlohách lze pozorovat u třídy č. 3 borovice lesní a č. 6 buk lesní. Modifikací parametrů algoritmu Neural Network bylo dosaženo téměř stejných rozloh

klasifikovaných pixelů do třídy č. 0 ostatní porostní typ, kde lze pozorovat rozdíl pouze při použití původně přednastavených parametrů. Dále se liší rozlohy třídy č. 3 borovice lesní, která v případě ponechání původních parametrů algoritmu dosáhla o téměř 7 % menší rozlohy než při použití Neural Network Mod3.

Tabulka 12: Rozloha klasifikovaných tříd z dat Landsat 8. Zkratky: ML = Maximum Likelihood; SVM – RBF = Support Vector Machine s radiální bázovou funkcí jádrové transformace; SVM – Poly6 = Support Vector Machine s polynomickou funkcí jádrové transformace 6. stupně; NN – Def = Neural Network s původními parametry; NN – Mod 1 = TTC = 0.4, TR = 0.1 a počet iterací = 3000; NN – Mod 2 = TTC = 0.2, TR = 0.2 a TM = 0.4 NN – Mod 3 = TTC = 0.1, TR = 0.2, TM = 0.5 a počet iterací = 1000; S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)

	ML	SVM – RBF	SVM – Poly 6	NN – Default	NN – Mod1	NN – Mod2	NN – Mod3
třída	rozloha (%)	rozloha (%)	rozloha (%)	rozloha (%)	rozloha (%)	rozloha (%)	rozloha (%)
ostatní porostní typ	3,92	11,90	13,18	0,42	12,11	2,75	3,11
smrk ztepilý	49,67	54,06	52,40	21,39	54,07	30,84	32,20
borovice lesní	11,56	22,28	22,22	57,33	16,99	51,90	50,37
modřín opadavý	11,74	0,00	0,00	0,00	0,03	0,00	0,01
dub letní	3,18	1,65	1,52	0,58	1,85	1,70	1,82
buk lesní	4,30	4,35	4,82	12,80	8,46	3,48	3,31
bříza bělokorá	4,12	0,00	0,00	0,00	0,00	0,00	0,00
holiny	6,94	3,99	3,94	6,19	4,82	7,63	7,42

Téměř shodných rozloh klasifikovaných tříd, jak lze vidět v Tabulce 12, dosáhl algoritmus Support Vector Machine, a to nezávisle na volbě jádrové transformace. O 2 % více bylo přiřazeno třídě č. 1 smrk ztepilý za použití radiální bázové funkce jádrové transformace. O necelá 2 % více bylo klasifikováno do třídy č. 0 ostatní porostní typ pomocí polynomické funkce jádrové transformace 6. stupně. Při použití algoritmu Maximum Likelihood, který jako jediný z použitých klasifikátorů, zařadil více než 4 % z celkové rozlohy zpracovávaného snímku Landsat 8 do třídy č. 9 bříza bělokorá. Klasifikátor Neural Network DEF zařadil společně s NN Mod2 a NN Mod3 nejvíce pixelů do třídy č. 3 borovice lesní, která přesahuje hodnotu 50 % z celkové


rozlohy. U první modifikace algoritmu Neural Network bylo nejvíce pixelů zařazeno do třídy č. 1 smrk ztepilý, jejíž rozloha dosáhla více jak 54 %.

5.2 Hodnocení jednotlivých klasifikátorů

Maximum Likelihood

Necelou polovinu z celkové rozlohy klasifikované scény Sentinel-2, jak lze vidět na Grafu 2, přiřadil klasifikátor Maximum Likelihood třídě č. 1 smrk ztepilý. Dále bylo téměř shodně pro oba zpracované snímky klasifikováno okolo 12 % jako třída č. 3 borovice lesní, 11 % jako třída č. 4 modřín opadavý. Rozdíl zhruba 2 % v závislosti na použitých datech lze vidět u klasifikované třídy č. 0 ostatní porostní typ. Třídy listnatého typu lesního porostu dosahují hodnot okolo 4 % z celkové rozlohy.

Graf 2: Relativní zastoupení tříd klasifikovaných metodou Maximum Likelihood. Zkratky: S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)



Nejvyšší hodnoty zpracovatelské přesnosti 90 %, dosáhl klasifikátor Maximum Likelihood při zpracování dat Sentinel-2, u třídy č. 11 holiny. Dále pak vyšších hodnot zpracovatelské přesnosti dosahuje třída č. 1 smrk ztepilý, který v obou případech použitých dat přesáhl 75% zpracovatelské přesnosti. Celkově vyšších hodnot zpracovatelské, ale i uživatelské přesnosti dosáhla klasifikace dat Sentinel-2. Nejnížší hodnoty zpracovatelské přesnosti dosáhla třída č. 0 ostatní porostní typ, který byl z téměř jedné třetiny misen třídou č. 1 a třídou č. 3. Nejvyšší hodnoty uživatelské přesnosti dosáhla třída č. 5 dub letní, který klasifikací dat Sentinel-2 dosáhl téměř 75 %.


Tabulka 13: Hodnocení přesnosti klasifikátoru Maximum Likelihood. Zkratky: PA = Zpracovatelská přesnost; UA = uživatelská přesnost; CE = chyby z opomenutí; OE = chyby z nesprávného zařazení; S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)

třída	PA		UA		CE		OE	
	S2	L8	S2	L8	S2	L8	S2	L8
ostatní porostní typ	7,54	5,53	53,93	40,68	46,07	59,32	92,46	94,47
smrk ztepilý	78,23	75,45	67,39	54,85	32,61	45,15	21,77	24,55
borovice lesní	74,51	66,52	61,36	65,53	38,64	34,47	25,49	33,48
modřín opadavý	72,57	54,05	14,46	12,03	85,54	87,97	27,43	45,94
dub letní	76,05	49,16	74,55	58,09	25,45	41,91	23,95	50,84
buk lesní	41,25	49,23	56,26	56,76	43,74	43,24	58,75	50,77
bříza bělokorá	40,13	26,70	14,58	11,27	85,42	88,73	59,87	73,30
holiny	90,11	81,79	77,37	58,79	22,63	41,21	0,89	18,21

Support Vector Machine s radiální bázovou funkcí jádrové transformace

Zpracováním obou snímků pomocí klasifikátoru Support Vector Machine s radiální bázovou funkcí jádrové transformace byla klasifikována necelá polovina území jako třída č. 1 smrk ztepilý. Jak lze na Grafu 3 vidět, necelou třetinu rozlohy zabírá třída č. 3 borovice lesní, která při klasifikaci snímku Sentinel-2 dosáhla hodnoty 29,65 % a pro Landsat 8 22,28 % z celkové rozlohy.

Graf 3: Relativní zastoupení tříd klasifikovaných metodou Support Vector Machine s radiální bázovou funkcí jádrové transformace. Zkratky: S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)



V předkládané práci klasifikátor Support Vector Machine s radiální bázovou funkcí jádrové transformace dosáhl nadprůměrných hodnot uživatelské přesnosti u 5 z 8 klasifikovaných tříd. Listnaté lesní porosty jsou zastoupeny třídou č. 6 buk lesní se zhruba 5 % rozlohy. Třída č. 4 a č. 9 nebyly klasifikované. Nejvyšší hodnoty zpracovatelské přesnosti bylo dosaženo u třídy č. 11 holiny, která se v případě dat Sentinel-2 pohybuje okolo 98 % a u dat Landsat 8 okolo 80 %. Dále lze z tabulky 14 vyčíst, že pro třídu č. 3 borovice lesní dosáhla hodnota zpracovatelské přesnosti klasifikace z dat Sentinel-2 téměř 90 %, avšak bylo dosaženo 51,43% uživatelské přesnosti. Obdobných hodnot zpracovatelské přesnosti 79 % pro oba dva zdroje klasifikovaných dat bylo dosaženo u třídy č. 1 smrk ztepilý. Uživatelská přesnost je však již rozdílná. V případě dat Sentinel-2 bylo dosaženo 69 % a pro data Landsat 8 necelých 53 %. Pro třídu č. 5 dub letní bylo klasifikací dat Sentinel-2 dosaženo uživatelské přesnosti 82,67 %, což je druhá nejvyšší dosažená uživatelská přesnost použitím algoritmu SVM – RBF. Zpracovatelská přesnost v tomto případě dosáhla 66,55 %.

Tabulka 14: Hodnocení přesnosti klasifikátoru Support Vector Machine s radiální bázovou funkcí jádrové transformace. Zkratky: PA = Zpracovatelská přesnost; UA = uživatelská přesnost; CE = chyby z opomenutí; OE = chyby z nesprávného zařazení; S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)


třída	PA		UA		CE		OE	
	S2	L8	S2	L8	S2	L8	S2	L8
ostatní porostní typ	22,06	15,68	46,26	34,55	53,74	65,45	77,94	84,32
smrk ztepilý	79,37	79,90	69,17	52,68	30,83	47,32	20,63	20,10
borovice lesní	89,12	68,91	51,43	47,43	48,57	52,57	10,88	31,09
modřín opadavý	0,00	0,00	0,00	0,00	0,00	0,00	100,00	100,00
dub letní	66,55	27,93	82,67	65,36	17,33	34,64	33,45	72,07
buk lesní	59,22	40,12	56,91	43,62	43,09	56,38	40,78	59,88
bříza bělokorá	0,00	0,00	0,00	0,00	0,00	0,00	100,00	100,00
holiny	98,03	80,71	94,32	79,41	5,68	20,59	1,97	19,29

Support Vector Machine s polynommickou funkcí jádrové transformace 6. stupně

Polynommická funkce 6. stupně jádrové transformace klasifikátoru Support Vector Machine přiřadila více než 52 % při zpracování dat Landsat 8 třídě č. 1 smrk ztepilý, v případě dat Sentinel-2 dosáhla zmíněná třída necelých 42 % celkové rozlohy. Dále bylo klasifikováno 28,93 % rozlohy z dat Sentinel-2 jako třída č. 3 borovice lesní. Použitím dat Landsat 8 dosáhla tato třída 22,22 % rozlohy. Okolo 15 % bylo dále

klasifikováno jako třída č. 0 ostatní porostní typ. Celkem zhruba 7 % bylo klasifikováno jako listnaté lesní porosty.

Graf 4: Relativní zastoupení tříd klasifikovaných metodou Support Vector Machine s polynomicou funkcí jádrové transformace 6. stupně. Zkratky: S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)



Tabulka 15: Hodnocení přesnosti klasifikátoru Support Vector Machine s polynomicou funkcí jádrové transformace 6. stupně. Zkratky: PA = Zpracovatelská přesnost; UA = uživatelská přesnost; CE = chyby z opomenutí; OE = chyby z nesprávného zařazení; S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)

třída	PA		UA		CE		OE	
	S2	L8	S2	L8	S2	L8	S2	L8
ostatní porostní typ	21,71	17,24	45,47	34,57	54,53	65,43	78,29	82,76
smrk ztepilý	80,59	77,97	69,64	53,94	30,36	46,06	19,41	22,03
borovice lesní	89,52	69,03	52,75	47,27	47,25	52,73	10,48	30,97
modřín opadavý	9,73	0,00	88,00	0,00	12,00	0,00	90,27	100,00
dub letní	69,66	28,21	82,41	69,90	17,59	30,10	30,34	71,79
buk lesní	58,28	43,36	57,09	43,91	42,91	56,09	41,72	56,64
bříza bělokorá	0,00	0,00	0,00	0,00	0,00	0,00	100,00	100,00
holiny	97,85	80,16	94,64	80,16	5,36	19,84	2,15	19,84


Nadprůměrných hodnot uživatelské přesnosti, jak lze vidět v Tabulce 15, dosáhl klasifikátor Support Vector Machine při aplikaci polynomicke funkce jádrové transformace 6. stupně na data Sentinel-2, u 5 z 8 klasifikovaných tříd. Jsou to třídy č. 1 smrk ztepilý, č. 3 borovice lesní, č. 5 dub letní, č. 6 buk lesní a č. 11 holiny. Klasifikací

dat Landsat 8 dosáhly nadprůměrných hodnot uživatelské přesnosti třídy č. 1 smrk ztepilý, č. 3 borovice lesní, č. 6 buk lesní a č. 11 holiny. S druhou nejvyšší uživatelskou přesností 88 % byla z dat Sentinel-2 klasifikována třída č. 4 modřín opadavý, který dosáhl necelých 10 % zpracovatelské přesnosti. V případě dat Landsat 8 nebyla tato třída klasifikována.

Neural Network s původně nastavenými parametry (Default)

S ponechanými přednastavenými parametry algoritmus Neural Network klasifikoval nadpoloviční většinu území z dat Landsat 8 jako třídu č. 3 borovice lesní, což je znázorněno na Grafu 5. Použitím dat Sentinel-2 dosáhla tato třída necelých 19 % rozlohy. Nejvíce pixelů z dat Sentinel-2 totiž bylo klasifikováno jako třída č. 1 smrk ztepilý. Rozdíl v použitých datech téměř 22 % lze vidět u třídy č. 0 ostatní porostní typ.

Graf 5: Relativní zastoupení tříd klasifikovaných metodou Neural Network s původními parametry. Zkratky: S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)



Klasifikovaná třída č. 3 borovice lesní dosáhla klasifikací obou datových zdrojů algoritmem Neural Network s původními parametry více jak 86 % zpracovatelské přesnosti. Jak lze vidět v Tabulce 16, pro zmíněnou třídu bylo dosaženo uživatelské přesnosti 58,55 % u dat Sentinel-2 a 30,53 % u dat Landsat 8. K největšímu mísení v tomto případě dochází s třídou č. 0 a č. 1. Téměř 57% zpracovatelské přesnosti při použití dat Sentinel-2 a 8 % u dat Landsat 8, bylo dosaženo u třídy č. 5 dub letní.

Ten však dosáhl téměř 86% uživatelské přesnosti pro data Sentinel-2 a 66,67% pro data Landsat 8. Dále byla z dat Sentinel-2 klasifikována třída č. 4 modřín opadavý se zpracovatelskou přesností 41,59 % a uživatelskou přesností 56,29 %. Z dat Landsat 8 tato třída nebyla klasifikována.

Tabulka 16: Hodnocení přesnosti klasifikátoru Neural Network s původními parametry. Zkratky: PA = Zpracovatelská přesnost; UA = uživatelská přesnost; CE = chyby z opomenutí; OE = chyby z nesprávného zařazení; S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)


třída	PA		UA		CE		OE	
	S2	L8	S2	L8	S2	L8	S2	L8
ostatní porostní typ	28,20	0,28	45,11	30,00	54,89	70,00	71,80	99,72
smrk ztepilý	77,74	38,78	71,09	66,64	28,91	33,36	22,26	61,22
borovice lesní	86,79	86,87	58,55	30,53	41,45	69,47	13,21	13,13
modřín opadavý	41,59	0,00	56,29	0,00	43,71	0,00	58,41	100,00
dub letní	56,89	8,10	85,59	66,67	14,41	33,33	43,11	91,90
buk lesní	65,75	72,53	49,61	30,86	50,39	69,14	34,25	27,47
bříza bělokorá	0,00	0,00	0,00	0,00	0,00	0,00	100,00	100,00
holiny	96,78	84,24	93,60	63,52	6,40	36,48	3,22	15,76

Neural Network s první modifikací parametrů

První modifikací klasifikátoru Neural Network, jak lze vidět na Grafu 6, byla při použití obou zpracovávaných snímků klasifikována necelá polovina rozlohy do třídy č. 1 smrk ztepilý. Užitím dat Landsat 8 dosáhla třída č. 1 smrk ztepilý 54 % rozlohy, u dat Sentinel-2 necelých 47 % rozlohy. Třída č. 3 borovice lesní, dosáhla klasifikované rozlohy téměř 17 % z dat Landsat 8 a 23,18 % z dat Sentinel-2. Oproti těmto vysokým hodnotám bylo z dat Sentinel-2 klasifikováno necelých 8 % listnatých lesních porostů a z dat Landsat 8 méně než 10 % celkové rozlohy.

Nadprůměrných hodnot uživatelské přesnosti bylo dosaženo u 4 z celkem 8 klasifikovaných tříd při použití klasifikátoru Neural Network s první modifikací parametrů na data Sentinel-2. U třídy č. 4 modřín opadavý bylo dosaženo zpracovatelské přesnosti 32,74 %, které bylo dosaženo s 60% uživatelskou přesností. Třída č. 9 bříza bělokorá, jak lze z Tabulky 17 vidět, nebyla vůbec klasifikována. Obdobně vysokých hodnot, přesahujících 80 % zpracovatelské přesnosti bylo dosaženo klasifikací obou snímků do třídy č. 1 smrk ztepilý. Uživatelská přesnost dosáhla pro uvedenou třídu 67,60 % (Sentinel-2) a 55,04 % (Landsat 8).

Graf 6: Relativní zastoupení tříd klasifikovaných metodou Neural Network s první modifikací (TTC = 0.4, TR = 0.1 a počet iterací = 3000). Zkratky: S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)



Tabulka 17: Hodnocení přesnosti klasifikátoru Neural Network s první modifikací (TTC = 0.4, TR = 0.1 a počet iterací = 3000). Zkratky: PA = Zpracovatelská přesnost; UA = uživatelská přesnost; CE = chyby z opomenutí; OE = chyby z nesprávného zařazení; S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)


třída	PA		UA		CE		OE	
	S2	L8	S2	L8	S2	L8	S2	L8
ostatní porostní typ	20,61	15,08	49,68	37,03	50,32	62,97	79,39	84,92
smrk ztepilý	84,76	82,01	67,60	55,04	32,40	44,96	15,24	17,99
borovice lesní	87,72	74,50	56,66	58,08	43,34	41,92	12,28	25,50
modřín opadavý	32,74	0,00	60,16	0,00	39,84	0,00	67,26	100,00
dub letní	78,32	34,78	75,16	78,06	24,84	21,94	21,68	65,22
buk lesní	54,78	64,20	60,06	42,06	39,94	57,94	45,22	35,80
bříza bělokorá	0,00	0,00	0,00	0,00	0,00	0,00	100,00	100,00
holiny	97,50	82,88	92,53	74,94	7,47	25,06	2,50	17,12

Neural Network s druhou modifikací parametrů

Z družicových dat Landsat 8 bylo, užitím algoritmu Neural Network s druhou modifikací parametrů, klasifikováno více než 50 % z celkové rozlohy do třídy č. 3 borovice lesní, 30,84 % do třídy č. 1 smrk ztepilý, téměř 3 % do třídy č. 0 ostatní porostní typy a necelá 4 % do třídy č. 6 buk lesní. Užitím dat Sentinel-2, což lze vidět na Grafu 7, bylo nejvíce pixelů klasifikováno jako třída č. 1 smrk ztepilý. Dále čtvrtina

rozlohy do třídy č. 3 borovice lesní, necelých 15 % do třídy č. 0 ostatní porostní typy a 7,58 % do třídy č. 6 buk lesní.

Graf 7: Relativní zastoupení tříd klasifikovaných metodou Neural Network s druhou modifikací (TTC = 0.2, TR = 0.2 a TM = 0.5). Zkratky: S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)



Tabulka 18: Hodnocení přesnosti klasifikátoru Neural Network s druhou modifikací (TTC = 0.2, TR = 0.2 a TM = 0.5). Zkratky: PA = Zpracovatelská přesnost; UA = uživatelská přesnost; CE = chyby z opomenutí; OE = chyby z nesprávného zařazení; S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)

třída	PA		UA		CE		OE	
	S2	L8	S2	L8	S2	L8	S2	L8
ostatní porostní typ	18,59	2,77	46,45	20,13	53,55	79,87	81,41	97,23
smrk ztepilý	81,60	50,67	70,42	61,03	29,58	38,97	18,40	49,33
borovice lesní	89,63	85,99	53,77	31,96	46,23	68,04	10,37	14,01
modřín opadavý	25,22	0,00	59,38	0,00	40,63	0,00	74,78	100,00
dub letní	53,70	28,91	88,02	69,23	11,98	30,77	46,30	71,09
buk lesní	73,13	46,76	47,86	49,75	52,14	50,25	26,87	53,24
bříza bělokora	0,00	0,00	0,00	0,00	0,00	0,00	100,00	100,00
holiny	98,21	85,33	94,17	57,51	5,83	42,49	1,79	14,67


Nadprůměrných hodnot uživatelské přesnosti, užitím algoritmu Neural Network s druhou modifikací parametrů, bylo u klasifikace obou snímků dosaženo u 4 z celkem 8 klasifikovaných tříd (viz Tabulka 18). Druhé nejvyšší hodnoty zpracovatelské přesnosti, po třídě č. 11 holiny, dosáhla třída č. 3 borovice lesní. Z dat Sentinel-2 byla

klasifikována s uživatelskou přesností 53,77 % a z dat Landsat 8 s 31,96 %. Třída č. 4 modřín opadavý dosáhl klasifikací dat Sentinel-2 zpracovatelské přesnosti 25,22 % a uživatelské přesnosti 59,38 %. Z dat Landsat 8 nebyla tato třída klasifikována.

Neural Network se třetí modifikací parametrů

Více než polovina z celkové rozlohy území byla z dat Landsat 8 klasifikována pomocí algoritmu Neural Network se třetí modifikací parametrů do třídy č. 3 borovice lesní. Dále 32,2 % bylo přiřazeno třídě č. 1 smrk ztepilý. Třídě č. 0 a č. 6 bylo klasifikováno po třech procentech rozlohy. Jak lze vidět na Grafu 8, tak z dat Sentinel-2 bylo přiřazeno třídě č. 3 borovice lesní necelých 26 %, třídě č. 1 smrk ztepilý 43,52 %, dále pak 14,42 % rozlohy připadlo třídě č. 0 ostatní porostní typy. Z listnatých lesních porostů bylo nejvíce pixelů klasifikováno třídě č. 6 buk lesní.

Graf 8: Relativní zastoupení tříd klasifikovaných metodou Neural Network se třetí modifikací (TTC = 0.1, TR = 0.2, TM = 0.5 a počet iterací = 3000). Zkratky: S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)



Třetí modifikací řízeného algoritmu Neural Network bylo dosaženo klasifikace dat Sentinel-2 více jak 90 % zpracovatelské přesnosti u klasifikace třídy č. 3 borovice lesní, což lze vidět v Tabulce 19. Klasifikací dat Landsat 8 bylo u této třídy dosaženo 85,74 % zpracovatelské přesnosti. Nadprůměrných hodnot zpracovatelské přesnosti dosáhla i třída č. 1 smrk ztepilý. Druhé nejvyšší hodnoty uživatelské přesnosti bylo dosaženo u třídy č. 5 dub letní, který byl klasifikován s 50,76 % zpracovatelskou přesností.

Třída č. 4 modřín opadavý byl z dat Sentinel-2 klasifikován s 26,55% zpracovatelskou přesností, u které bylo dosaženo 69,77% uživatelské přesnosti. Třída č. 9 bříza bělokorá nebyla klasifikována.

Tabulka 19: Hodnocení přesnosti klasifikátoru Neural Network se třetí modifikací (TTC = 0.1, TR = 0.2, TM = 0.5 a počet iterací = 3000). Zkratky: PA = Zpracovatelská přesnost; UA = uživatelská přesnost; CE = chyby z opomenutí; OE = chyby z nesprávného zařazení; S2 = Sentinel-2; L8 = Landsat 8 (zdroj: vlastní zpracování)

třída	PA		UA		CE		OE	
	S2	L8	S2	L8	S2	L8	S2	L8
ostatní porostní typ	18,67	2,81	45,37	18,48	54,63	81,52	81,33	97,19
smrk ztepilý	81,57	52,82	70,19	59,85	29,81	40,15	18,42	47,18
borovice lesní	90,37	85,74	53,33	32,92	46,67	67,08	9,63	14,26
modřín opadavý	26,55	0,00	69,77	0,00	30,23	0,00	73,45	100,00
dub letní	50,76	28,77	88,95	67,54	11,05	32,46	49,24	71,23
buk lesní	70,86	45,83	47,92	49,92	52,08	50,08	29,14	54,17
bříza bělokorá	0,00	0,00	0,00	0,00	0,00	0,00	100,00	100,00
holiny	98,21	85,33	93,53	58,58	6,47	41,42	1,79	14,67

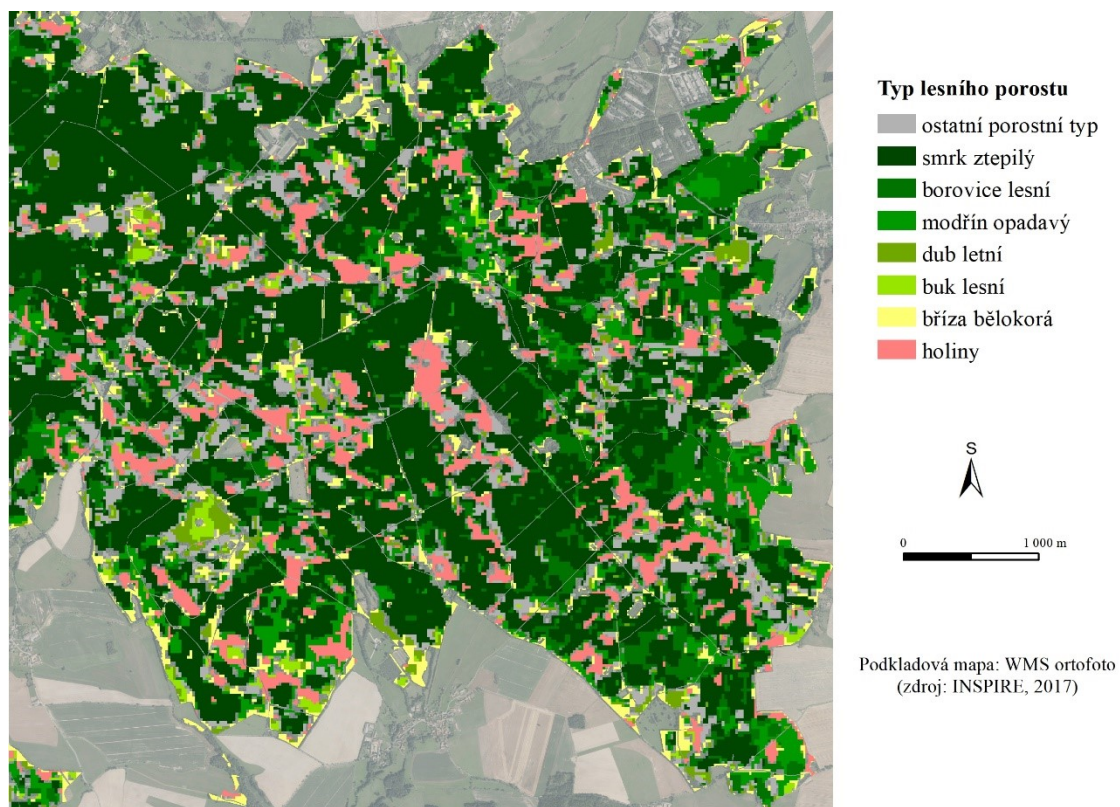
5.3 Mapy klasifikovaného území použitými algoritmy

Na následujících Obrázcích 11–24 je zobrazen výřez zájmového území PLO 7. Pro porovnání výsledků aplikovaných klasifikačních algoritmů byl výřez zaměřen na tu část území, kde bylo možné znázornit většinu klasifikovaných tříd ze všech použitých algoritmů. Mapy klasifikovaného území jsou přílohami práce.

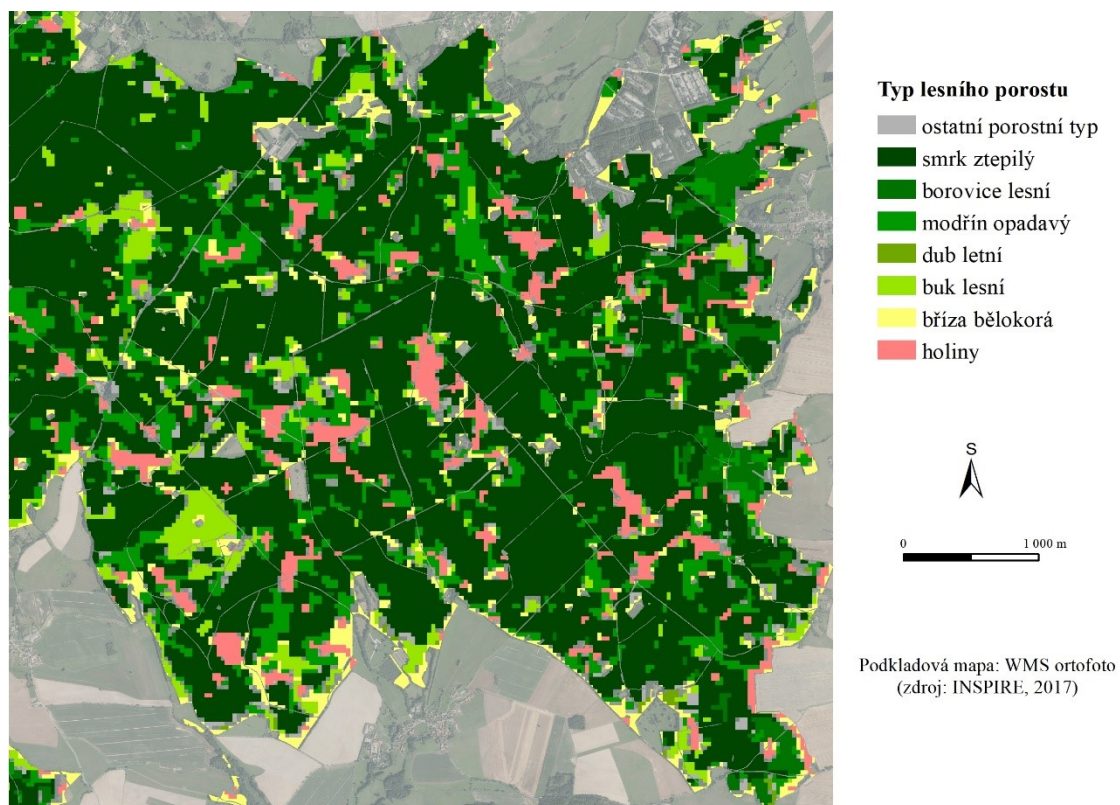
Zvolené třídy lesního porostu jsou odlišeny odstíny zelené. Dále bylo přidáno ortofoto INSPIRE jakožto podkladová mapa, která může posloužit lepší orientaci v prostoru.

Mapový výřez je doplněn měřítkem a směrovou růžicí. Zvolené zobrazení mapy odpovídá zpracovávaným snímkům. Jedná se o WGS_1984_UTM_Zone_33N.

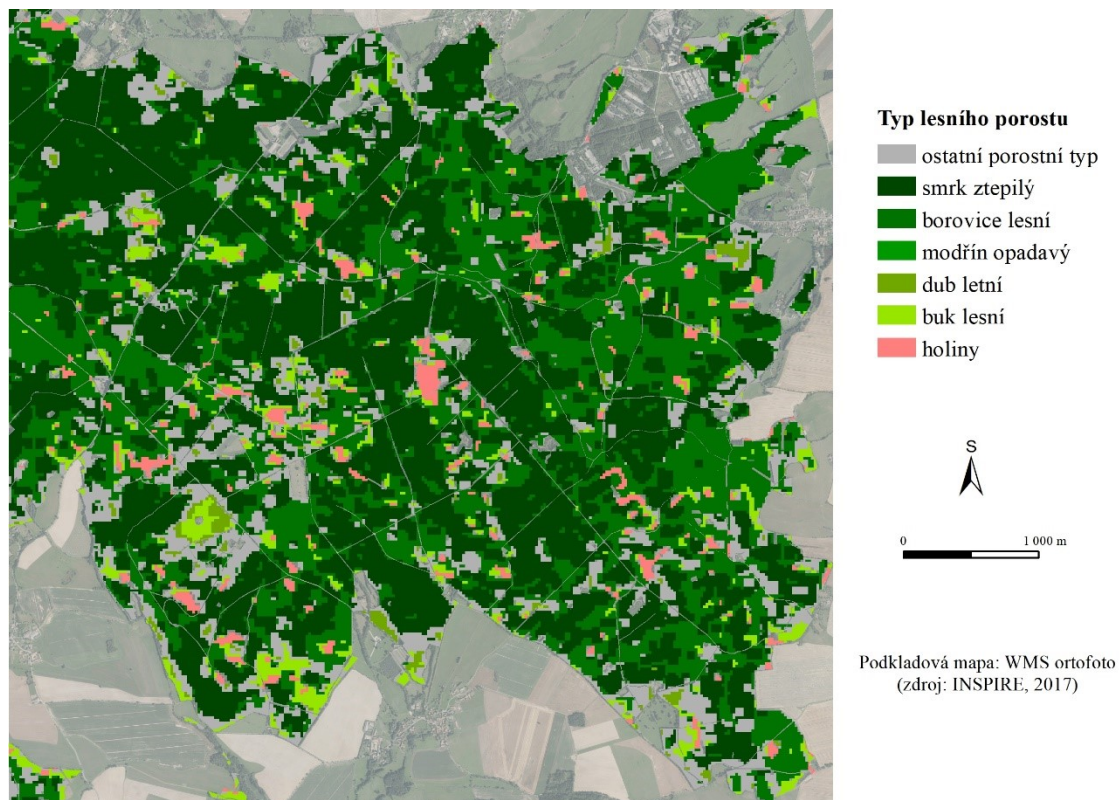
Obrázek 11: Výřez klasifikovaného území z dat Sentinel-2 algoritmem ML (zdroj: vlastní zpracování)



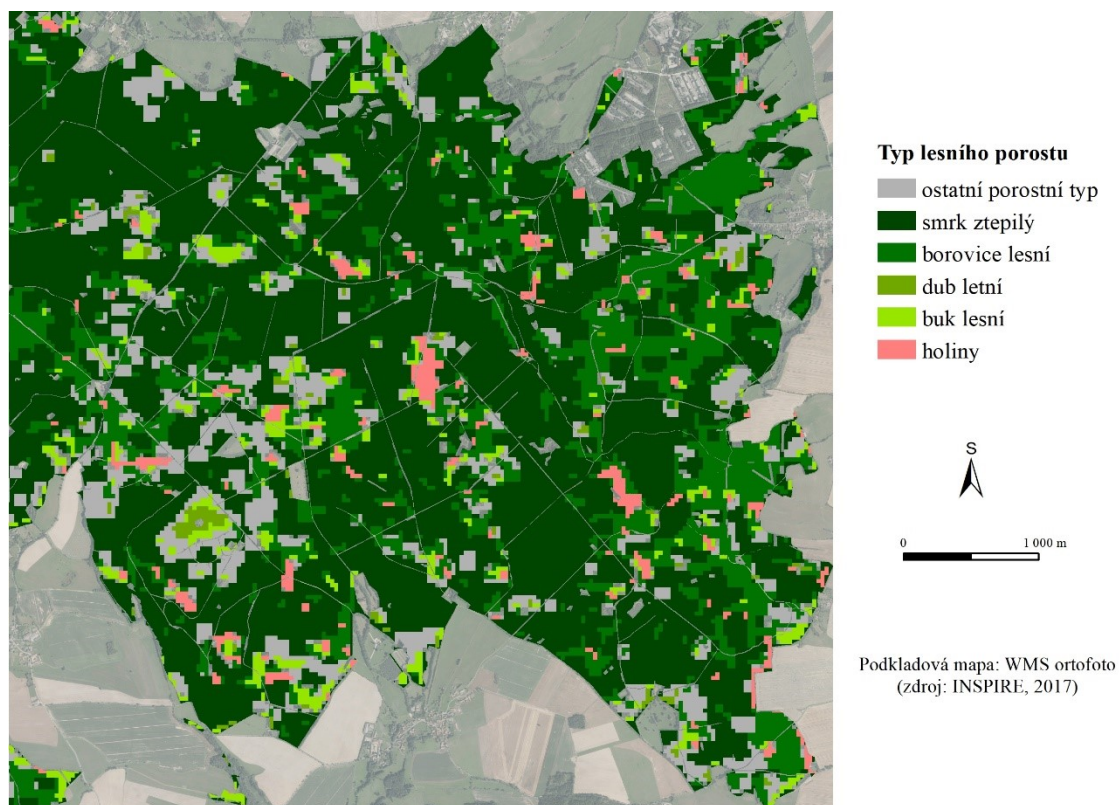
Obrázek 12: Výřez klasifikovaného území z dat Landsat 8 algoritmem ML (zdroj: vlastní zpracování)



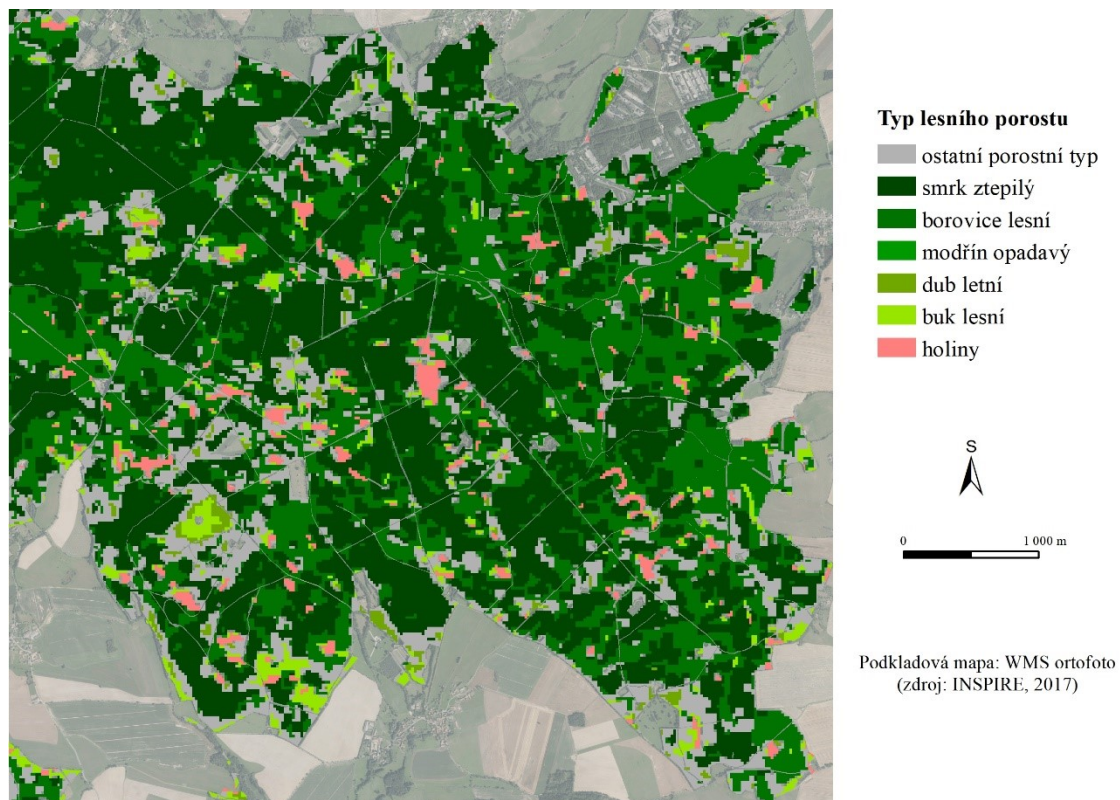
Obrázek 13: Výřez klasifikovaného území z dat Sentinel-2 algoritmem SVM – RBF (zdroj: vlastní zpracování)



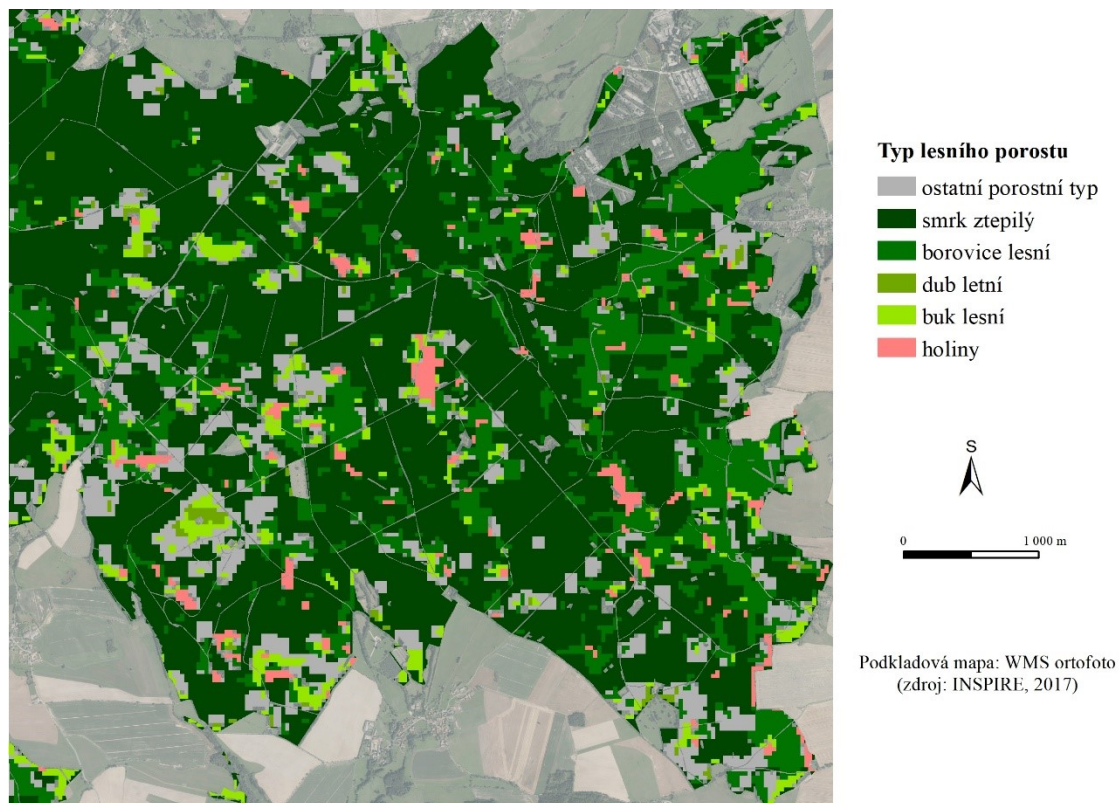
Obrázek 14: Výřez klasifikovaného území z dat Landsat 8 algoritmem SVM – RBF (zdroj: vlastní zpracování)



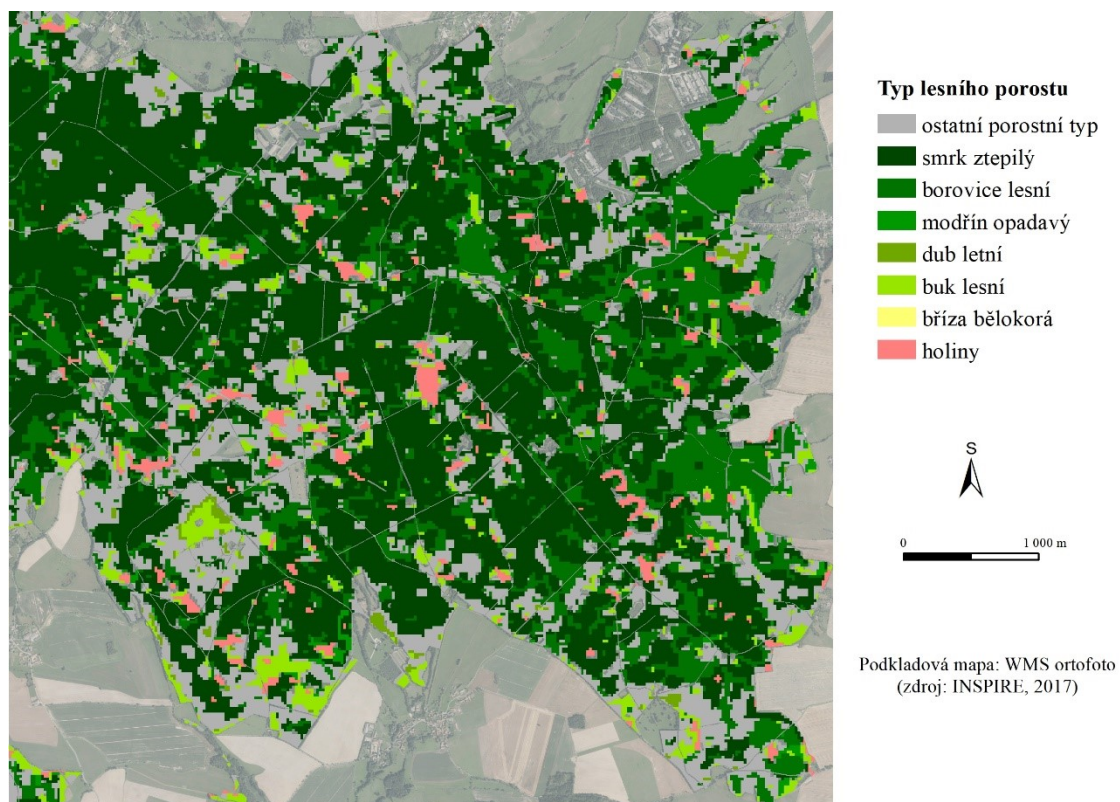
Obrázek 15: Výřez klasifikovaného území z dat Sentinel-2 algoritmem SVM – POLY6
(zdroj: vlastní zpracování)



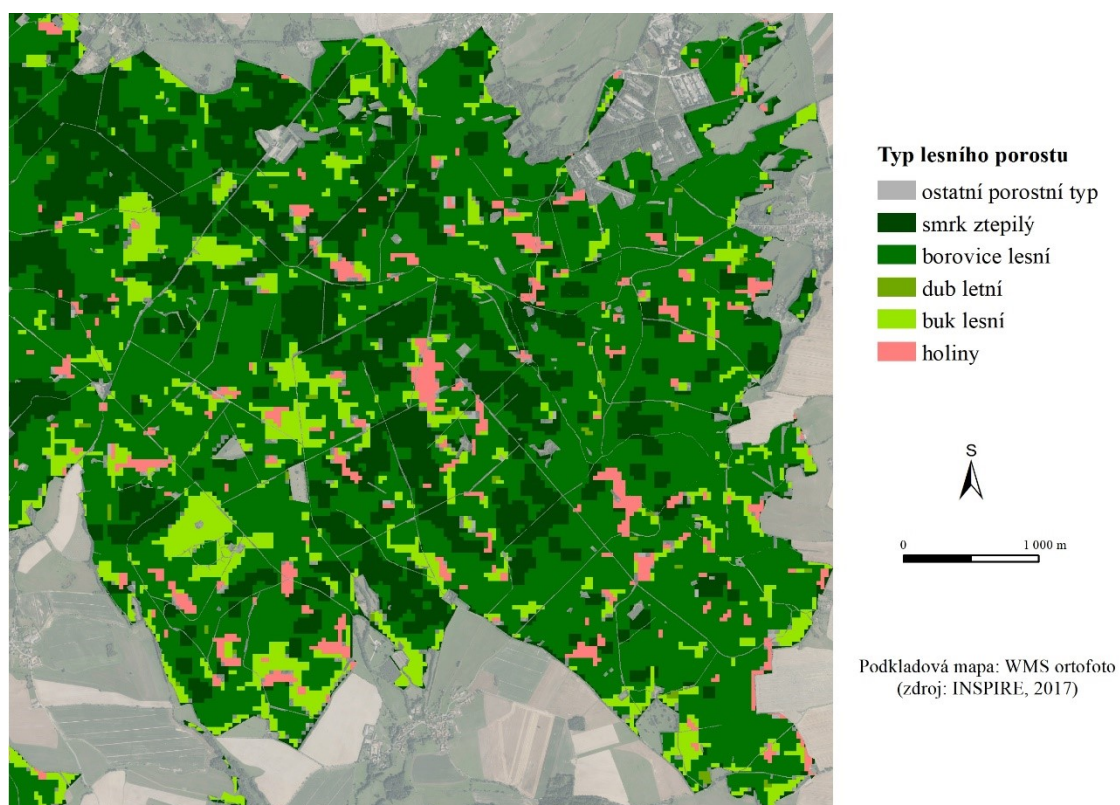
Obrázek 16: Výřez klasifikovaného území z dat Landsat 8 algoritmem SVM – POLY6
(zdroj: vlastní zpracování)



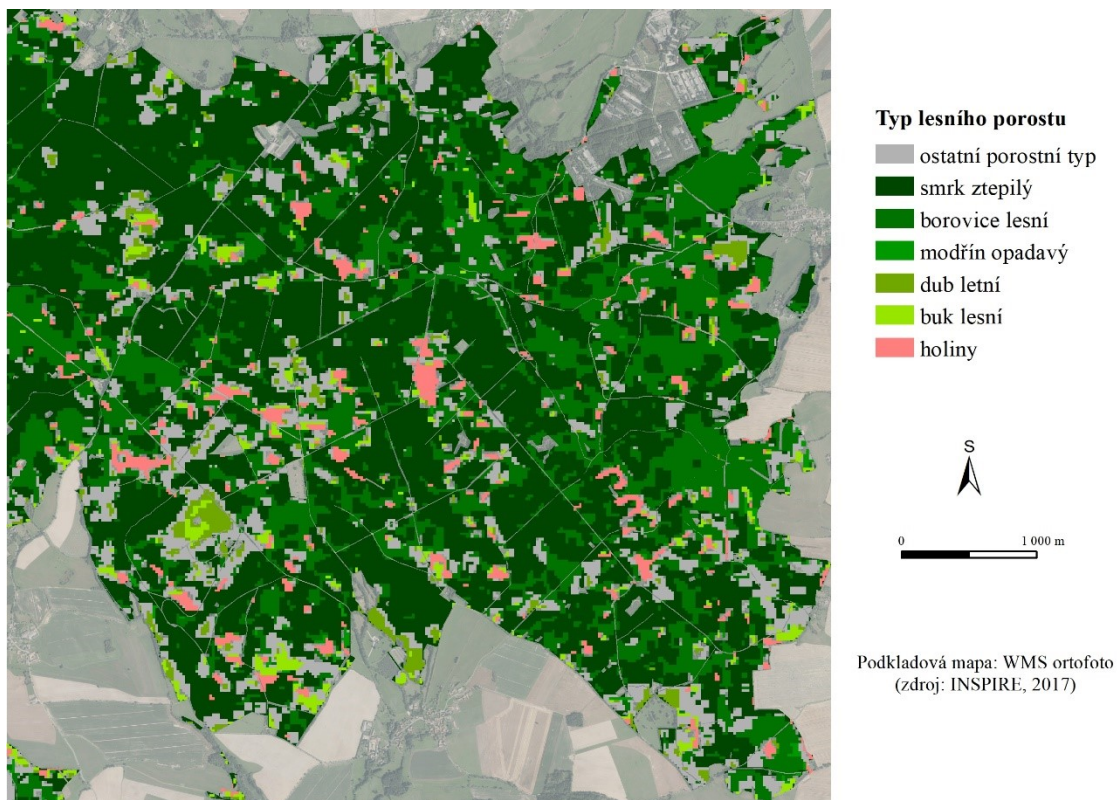
Obrázek 17: Výřez klasifikovaného území z dat Sentinel-2 algoritmem NN – Default (zdroj: vlastní zpracování)



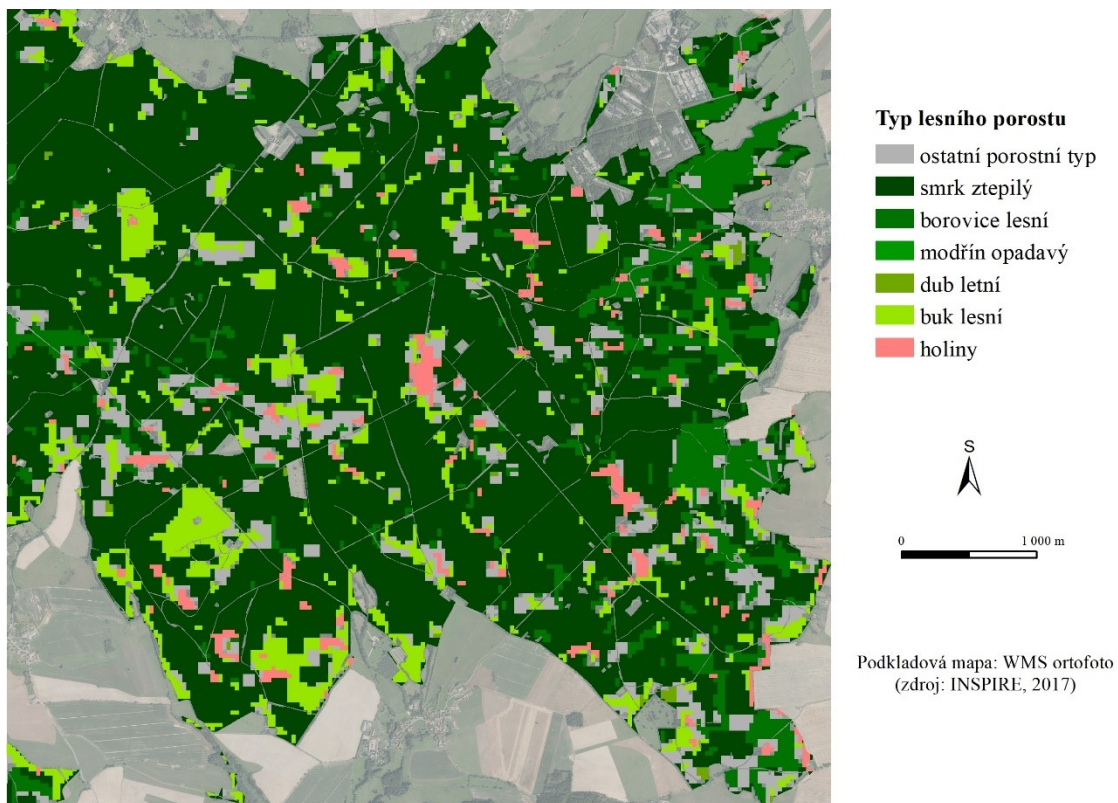
Obrázek 18: Výřez klasifikovaného území z dat Landsat 8 algoritmem NN – Default (zdroj: vlastní zpracování)



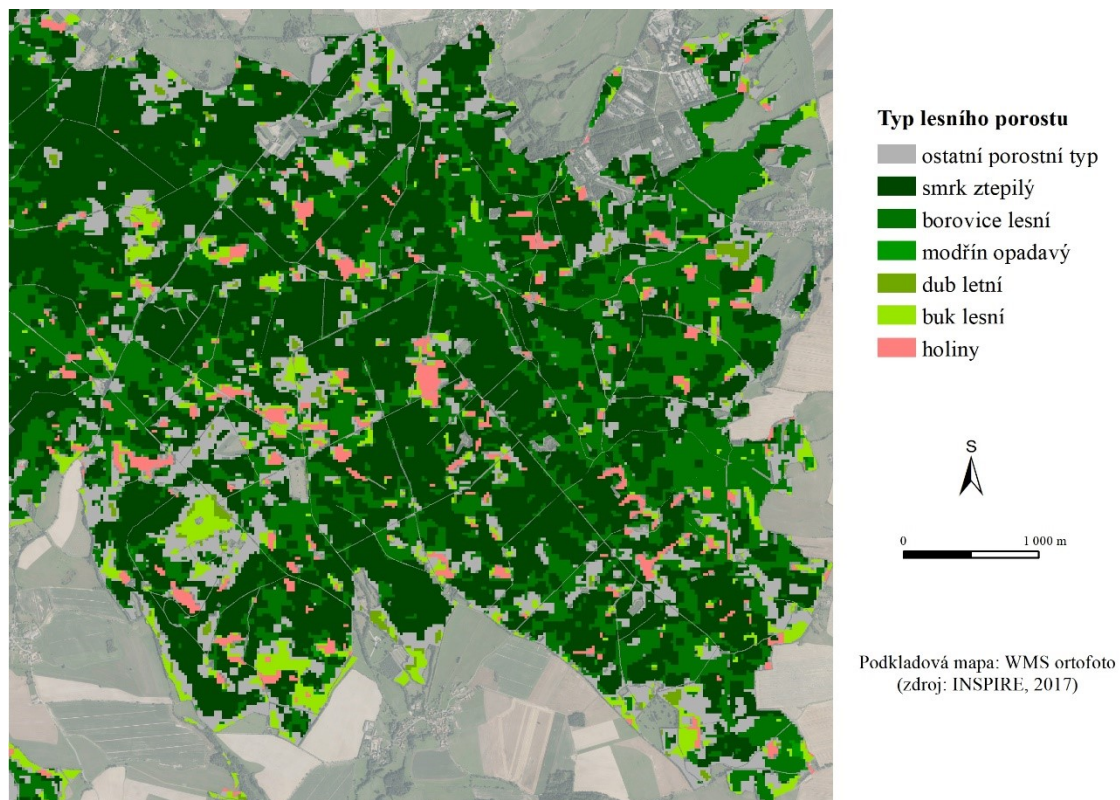
Obrázek 19: Výřez klasifikovaného území z dat Sentinel-2 algoritmem NN – Mod1 (zdroj: vlastní zpracování)



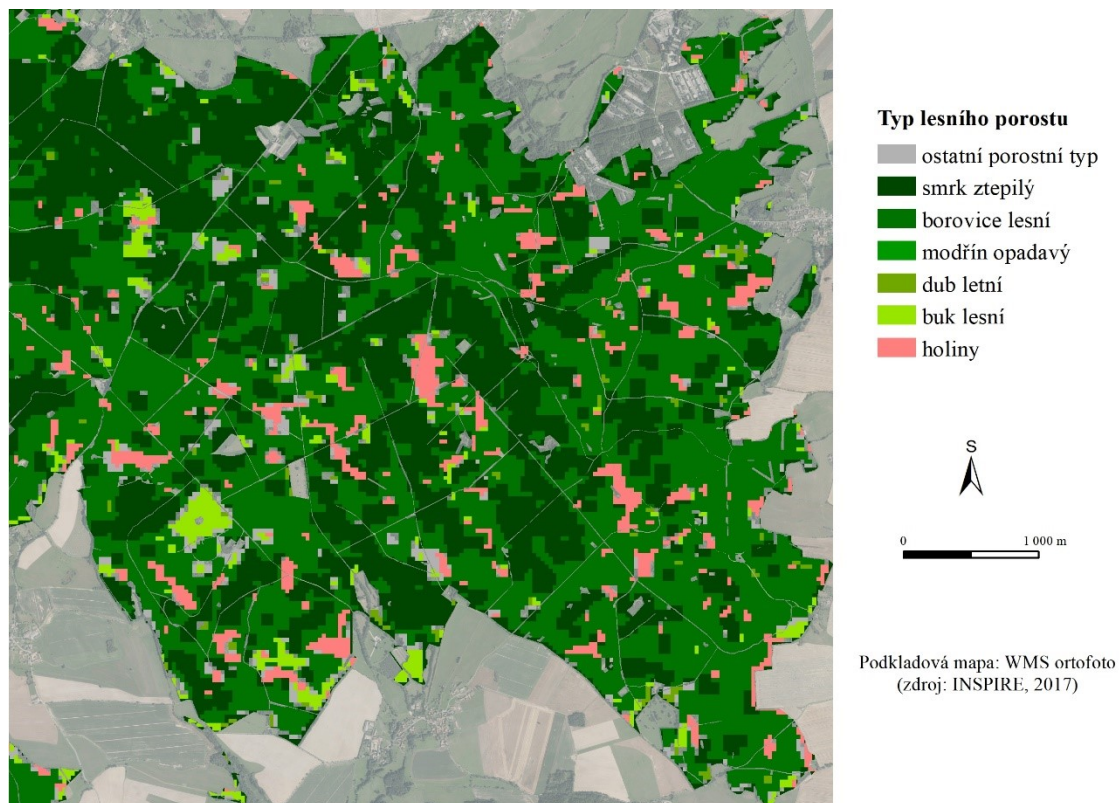
Obrázek 20: Výřez klasifikovaného území z dat Landsat 8 algoritmem NN – Mod1 (zdroj: vlastní zpracování)



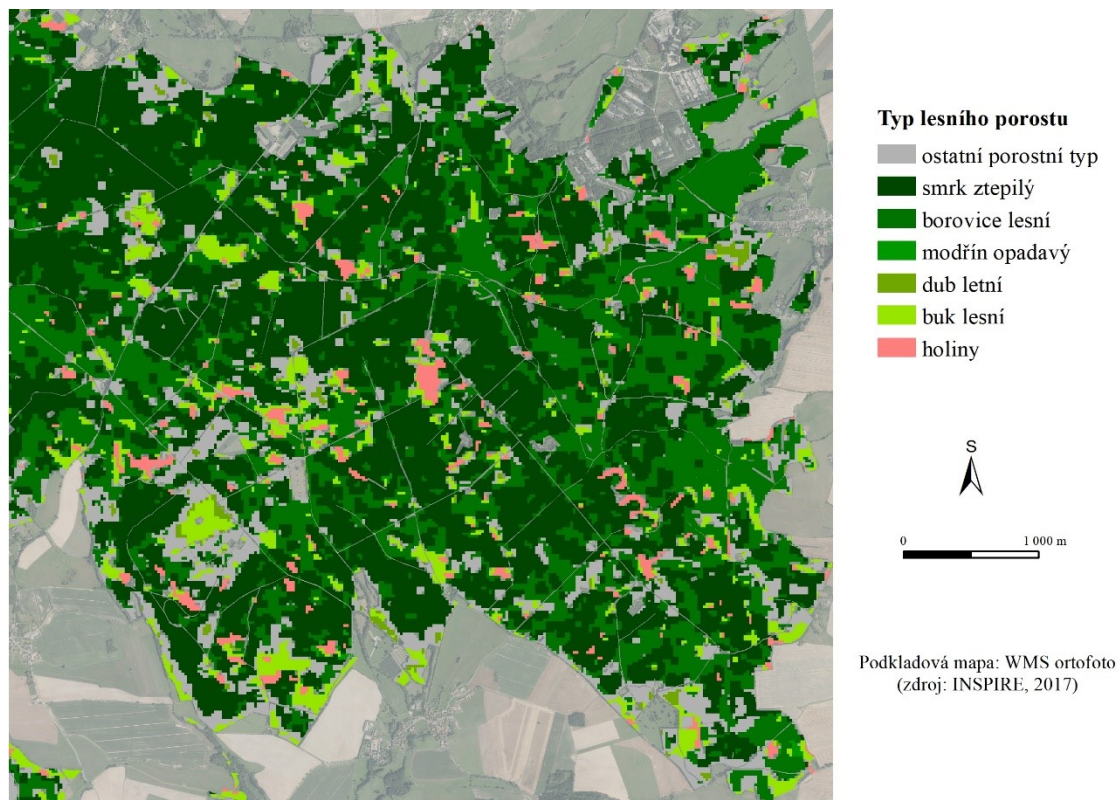
Obrázek 21: Výřez klasifikovaného území z dat Sentinel-2 algoritmem NN – Mod2 (zdroj: vlastní zpracování)



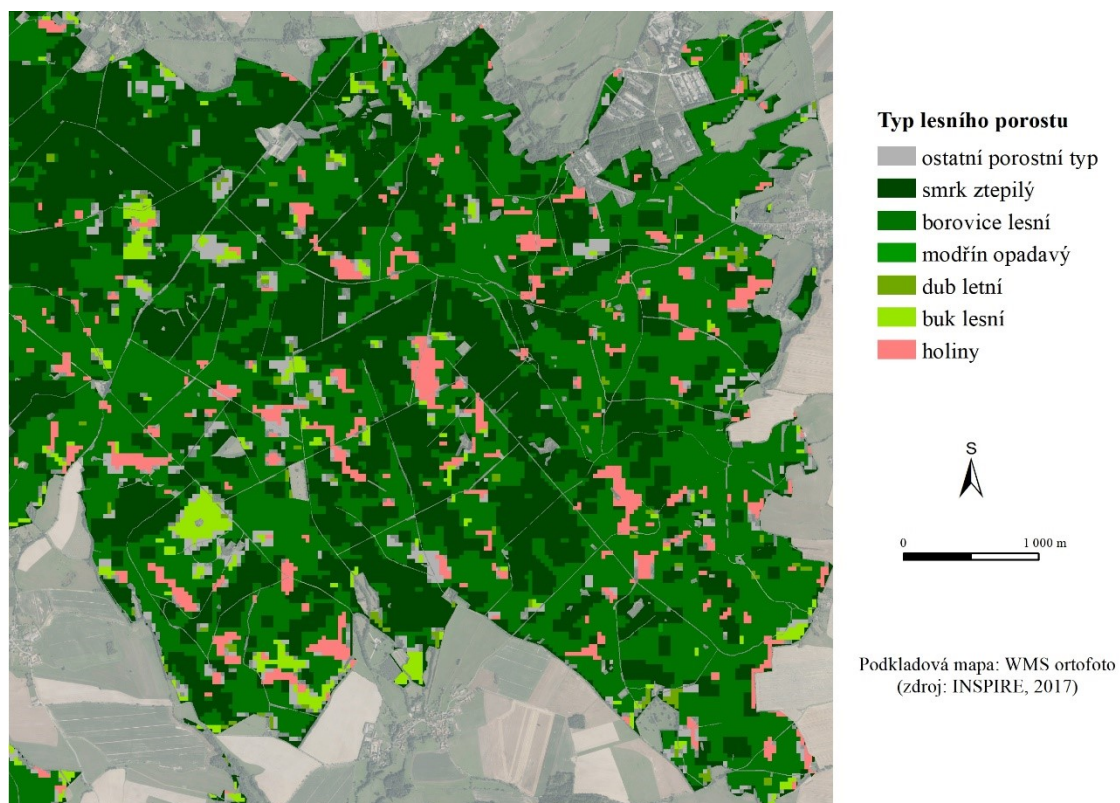
Obrázek 22: Výřez klasifikovaného území z dat Landsat 8 algoritmem NN – Mod2 (zdroj: vlastní zpracování)



Obrázek 23: Výřez klasifikovaného území z dat Sentinel-2 algoritmem NN – Mod3
(zdroj: vlastní zpracování)



Obrázek 24: Výřez klasifikovaného území z dat Landsat 8 algoritmem NN – Mod3
(zdroj: vlastní zpracování)



6 DISKUZE

Předkládaná diplomová práce se zabývala klasifikací satelitních snímků z družic Sentinel-2 a Landsat 8. Zvoleno bylo území přírodní lesní oblast Brdská vrchovina. Pro tvorbu nejvhodnějšího souboru trénovacích a kontrolních množin, které jsou nedílnou součástí řízené klasifikace, bylo využito polygonové vrstvy od Ústavu pro hospodářskou úpravu lesů. Poskytnutá polygonová vrstva obsahuje informace o strukturním porostním typu a jeho mísení. Tato data pochází přímo od odborných zaměstnanců ÚHUL, kteří polygony vymezili na základě terénního výzkumu, při kterém taktéž označili typ SPT. Předpokladem tedy bylo, že až na drobné odchylky budou atributy polygonů odpovídat skutečnosti.

6.1 Volba nejvhodnějšího souboru trénovacích a kontrolních množin

Zájmové území pro zpracování této práce bylo vybráno z několika důvodů. Jedním z nich byla lesnatost, která se pohybuje okolo 50 % z celkové rozlohy. Otázkou je, zda zvolené zájmové území není příliš velké pro takhle podrobné klasifikace na úrovni rozlišení jednotlivých typů lesního porostu. Jak již bylo zmíněno v kapitole 3, převažujícím typem lesního porostu je smrk ztepilý, jehož rozsah je odhadován pracovníky ÚHUL na 70–80 %. Ten je doplňován dalšími typy jehličnatého lesního porostu, které společně se smrkem tvoří více než 90 % rozlohy zalesněných ploch. Pro předkládanou práci bylo zvoleno ke klasifikaci tři jehličnanů a tři listnáčů. Zatímco zmiňované jehličnaté lesní porosty dosahují většinového rozsahu, lze na území nalézt i listnaté zastoupení. Je však řádově menší a tvoří necelých 10 % zalesněných ploch. Je zde otázkou, zda neměly být zvoleny pouze 4 kategorie s největším plošným zastoupením, jako použil Launer (2018) ve své diplomové práci. Odpovědi mohou být provedené analýzy separability, které předcházely samotné volbě nejvhodnějšího souboru trénovacích a kontrolních množin.

Již v kapitole 4 bylo autorem práce nastíněno, že prostorové vymezení polygonů, reprezentující uvedený typ lesního porostu, neodpovídá skutečnosti. Bylo provedeno podrobné porovnání dle ortofota od INSPIRE, které dosahuje prostorového rozlišení 10 metrů, což lze předpokládat za dostačující hodnotu vzhledem k velikosti pixelu 20 m u zpracovávaného snímku Sentinel-2 a 30 m u dat Landsat 8. Dále byla data porovnána s oběma zpracovávanými snímky. Pro lepší rozlišitelnost lesních porostů zde byla

využita kombinace spektrálních pásem v nepravých barvách, která lesní porosty charakterizuje různými odstíny a sytostí červené barvy. Lze tedy jasně rozeznat lesní porosty od zástavby a vodních ploch, polí a luk, které by však polygonová vrstva od ÚHUL neměla obsahovat. Dalo se očekávat, že budou nalezeny rozdílné informace o porostním typu, jelikož ortofoto bylo snímáno v roce 2017, zatímco polygonová vrstva od ÚHUL pochází z roku 2016. Launer (2018) ve své práci uvádí, že rozdíl jednoho roku pro kontrolu nehraje roli, jelikož vykácený les se za tak krátkou dobu nestihne přeměnit v louku.

Další problematickou částí při volbě nejvhodnějšího souboru trénovacích a kontrolních množin bylo mísení porostního typu sousedících polygonů. Snahou autora odstranit tato hraniční pásma byla aplikace funkce Buffer, která vymezí z obou stran hranice pásmo stanoveného rozsahu, které je následně možné z původních dat vymazat. Stanovený rozsah v předkládané práci odpovídal velikosti 1 pixelu (20 m) dat Sentinel-2, jakožto primárně uvažovaného zdroje satelitních dat. Vzhledem k pozvolnému přechodu mezi shluky monokultur lesního porostu, který je zapříčiněn občasným výskytem odlišného druhu SPT, je otázkou i velikost zmiňovaného hraničního pásma. Za úvahu také stojí volba charakteru smíšení (viz Tabulka 1). V předkládané práci bylo do 6 zvolených tříd porostního typu zařazeno pouze čistých polygonů, které obsahují jeden porostní typ se zastoupením 90–100 %. Vzhledem k možným nepřesnostem při samotném sběru dat v terénu, tak následném zpracování do elektronické podoby, se mohou charakterizované hranice lesních ploch lišit v rozsahu několika procent. Za těchto předpokladů by do samotného procesu výběru nejvhodnějšího souboru trénovacích a kontrolních množin mohla vstoupit i další kategorie charakteru smíšení.

Na základě postupu, uvedeného v metodice této práce, bylo vybráno 807 polygonů různé velikosti jako nejvhodnější soubor trénovacích množin a celkem 676 polygonů jako soubor množin kontrolních. Nutno podotknout, že původní počet polygonů, získaný od ÚHUL, obsahoval přes 65 000 polygonů odlišné velikosti, druhu SPT a především kvality prostorového vymezení daného typu lesního porostu. Zvolené polygony podstoupily hodnocení odlišitelnosti (separability). Jak uvádí Erbek, Özkan a Taberner (2004), celková přesnost klasifikace velice záleží na konzistenci, homogenitě, reprezentativnosti a separabilitě původního souboru trénovacích množin. Jak lze vidět z Tabulky 5, výsledné hodnoty divergencí dosahují odlišných hodnot

v závislosti na typu lesního porostu. Zatímco odlišnost v rámci kategorií jehličnaté a listnaté lesní porosty dosahuje hodnot okolo 1,5, při řešení separability jednotlivých tříd uvnitř kategorie jehličnaté či listnaté jsou hodnoty divergencí mnohokrát i pod hodnotou 1.

6.2 Spektrální pásma zpracovaných scén

V předkládané práci autor klasifikoval satelitní snímek z družice Sentinel-2, z jehož původních 13 spektrálních pásem jich bylo vybráno 9. Do klasifikace nevstoupily tři pásma s 60 m prostorovým rozlišením, tedy č. 1, č. 9 a č. 10, a jedno pásmo s 10 m prostorovým rozlišením. Právě desetimetrové pásmo č. 8 svým spektrálním rozsahem zahrnuje pásmo č. 8a, které je definováno v rozsahu 0,855 až 0,875 μm . Úzce vymezené spektrální pásmo č. 8a bylo navrženo jako náhrada pásma blízkého infračerveného u starších družic Landsat 7, které bývá kontaminováno vodní párou (ESA, 2018). Ze satelitního snímku Landsat 8, který snímá v celkem 11 spektrálních pásmech, bylo pro zpracování vybráno jen 6. Úroveň předzpracování, na které byla daná scéna Landsat 8, odpovídá přepočteným hodnotám na úrovni zemského povrchu a obsahuje již jen 7 spektrálních pásem. Autor z tohoto výběru dále odebral pobřežní pásmo č. 1.

V kapitole 4.3.3. ilustruje autor korelačním diagramem využitelnost všech použitých spektrálních pásem. Lze si ale povšimnout, že v případě dat Sentinel-2, se převážná část hodnot vyskytuje v rozmezí pásem B5 až B11. U dat Landsat 8 můžeme vidět, že převážná část hodnot se vyskytuje v rozmezí spektrálních pásem B4 až B6. Použití těchto vymezených pásem by mohlo ovlivnit kvalitu výsledné klasifikace. Volbou vhodné kombinace spektrálních pásem družice Sentinel-2 se zabýval ve své práci Immitzer (2016), který dospěl k závěru, že třemi nejvhodnějšími spektrálními pásmy pro klasifikaci jednotlivých lesních druhů jsou pásma B2, B5 a B11. Tím potvrdil shodnost i s dalšími pracemi, které kladou důraz na využívání pásma red-edge a shortwave infrared pro mapování vegetace.

6.3 Hodnocení přesnosti použitých klasifikačních algoritmů

Porovnáním celkové přesnosti klasifikace lze dospět k závěru, který algoritmus fungoval nejlépe na základě zvolených trénovacích množin. V předkládané práci byly porovnány celkem tři klasifikátory z kategorie řízené klasifikace. Předpokladem kvalitních hodnot přesnosti právě tohoto typu klasifikací je vhodně zvolený soubor

trénovacích množin. Jak lze z Tabulky 10 vidět, nejvyšší hodnoty 56,09 % celkové přesnosti bylo dosaženo použitím algoritmu Support Vector Machine s polynomicovou funkcí jádrové transformace 6. stupně ke klasifikaci dat Landsat 8. V případě klasifikace dat Sentinel-2 dosáhl nejvyšší celkové přesnosti 62,63 % algoritmus Neural Network s první modifikací parametrů. První zmíněný algoritmus SVM – Poly6 dosáhl u klasifikace dat Sentinel-2 celkové přesnosti 61,25 %, což je o zhruba 5 % více. Druhý zmíněný algoritmus dosáhl celkové přesnosti 53,4 % klasifikace dat Landsat 8, což je o zhruba 9 % méně. Rozdíl hodnot je dán nejspíše rozdílným prostorovým rozlišením. Limitujícím faktorem, který přímo ovlivňuje přesnost klasifikace, na který ve své práci poukazuje i Immitzer (2016), porovnával 10 m a 20 m prostorové rozlišení na klasifikaci dat Sentinel-2. Za účelem lepších možností porovnání dat Sentinel-2 a Landsat 8 převzorkovali Topaloglu, Sertel a Musaoglu (2016) ve své práci pásma Sentinel-2 do 30 m rozlišení. Pro oba klasifikované snímky dosáhl klasifikátor Support Vector Machine lepších hodnot celkové přesnosti než Maximum Likelihood a také byla získána vyšší přesnost u dat Sentinel-2 oproti Landsat 8. Autoři dále uvádí, že při použití stejných spektrálních pásem družic Sentinel-2 a Landsat 8, následném převzorkování na stejné 30 m rozlišení, dosahuje družice Sentinel-2 přesnějších výsledků z důvodu podědění původních spektrálních charakteristik 20 m prostorového rozlišení.

Sledovaný ukazatel přesnosti v předchozím odstavci však ne zcela dobře vypovídá o dílčích hodnotách uživatelské či zpracovatelské přesnosti pro klasifikované třídy. Zatímco průměrná hodnota celkové přesnosti se pohybuje okolo 60 % pro data Sentinel-2 a 48 % pro data Landsat 8, lze z kontingenčních tabulek, které jsou přílohami této práce vyčíst, že zpracovatelská přesnost třídy č. 1 smrk ztepilý je ve většině případů okolo 80 % pro data Sentinel-2 a 65 % pro data Landsat 8. Rozptylu hodnot zpracovatelské (12 %), ale i uživatelské (17 %) přesnosti si lze všimnout u třídy č. 0 ostatní porostní typy. Nejpravděpodobněji byla tato třída ve většině případů klasifikována chybně z důvodu velkého množství spektrálně odlišných polygonů, které reprezentují jak jehličnaté, tak listnaté lesní porosty. Jak již bylo v práci mnohokrát zmíněno, na výslednou přesnost klasifikace má vliv vhodně zvolený soubor trénovacích množin. Nedostatečný počet polygonů a nejspíše i výrazně menší celková plocha měla za následek velmi nízké hodnoty přesností u třídy č. 4 modřín opadavý a č. 9. bříza bělokorá.

Zaměřením se na modifikace dvou použitých algoritmů, kterými byly Support Vector Machine a Neural Network, je možné dosáhnout rozdílných hodnot jak celkové, tak i zpracovatelské a uživatelské přesnosti klasifikace. První zmíněný algoritmus s využitím radiální bázové funkce jádrové transformace využili ve své práci Shafri a Ramle (2009). Autoři se zabývali porovnáním algoritmů Support Vector Machine a Decision Tree ke klasifikaci ostrova Langkawi. Užitím zmíněné jádrové transformace dosáhli nejvyšších výsledků celkové přesnosti, která dosáhla 73 % pro snímek družice SPOT 5. V předkládané diplomové práci bylo dosaženo stejně nastaveným klasifikátorem celkové přesnosti 60,57 % pro data Sentinel-2 a 49,21 % pro Landsat 8. Nutno zde podotknout, že družice SPOT 5 má 2,5/5 m prostorové rozlišení. Volbou jádrové transformace se dále zabývaly ve svých pracích Hromádková (2016) a Šmausová (2017), které shodně označily polynomicou funkci 6. stupně za nejlepší. První zmíněná autorka dosáhla klasifikací hyperspektrálních dat na území o velikosti 0,2 km² celkové přesnosti 87,63 %. V práci Šmausové bylo klasifikováno území o rozloze 105 km² z dat Landsat 8 s celkovou přesností 70,59 %. Kromě zmiňovaného algoritmu Support Vector Machine se obě autorky zabývaly také klasifikací dat metodou Neural Network. Hromádková, která podrobnou analýzou velkého množství kombinací, dospěla k názoru, že ideální počet iterací je 3000, Training Rate 0,4 a Training Treshold Contribution 0,4. Touto kombinací dosáhla na stejném území klasifikací stejných dat obdobné celkové přesnosti 87,35 %. Použitím této kombinace parametrů bylo v předkládané práci dosaženo 62,62 % celkové přesnosti pro data Sentinel-2 a 53,40 % pro data Landsat 8. Další optimální kombinací parametrů algoritmu Neural Network, kterou Šmausová dosáhla celkové přesnosti 69,91 %, je počet iterací 1000, Training Rate 0,2 a Training Treshold Contribution 0,1 a Training Momentum 0,5. I tato kombinace byla otestována v předkládané práci a bylo dosaženo celkové přesnosti 60,49 % pro data Sentinel-2 a 42,45 % pro Landsat 8. Odlišné nastavení parametrů za nejlepší označila Oubrechtová (2012), která pracovala s Training Rate 0,2 a Training Treshold Contribution 0,2 a Training Momentum 0,4. Touto modifikací dosáhla celkové přesnosti 89,5 %. Zpracováním takto nastaveného algoritmu Neural Network bylo v předkládané práci dosaženo celkové přesnosti 60,74 % pro data Sentinel-2 a 41,98 % pro Landsat 8. Lze tedy vidět, že zatímco modifikací transformační jádrové funkce u algoritmu Support Vector Machine bylo dosaženo nepatrně lepších výsledků (1–2 %), klasifikátor Neural Network v modifikaci č. 2 a č. 3 u obou zpracovaných dat dosahuje rozdílu v řádech desetin procent.

Modifikace č. 1 algoritmu Neural Network dosáhla celkové přesnosti 62,62 % u dat Sentinel-2 a 53,40 % u Landsat 8. Rozdíl zhruba 9 % by mohl být zapříčiněn odlišně nastaveným parametrem Training Threshold Contribution. Jelikož při použití původně přednastavených parametrů ($TTC = 0,9$) daného algoritmu softwarem ENVI bylo dosaženo zejména u dat Landsat 8 horších výsledků celkové přesnosti ($S2 = 61,63$ %; $L8 = 38,42$ %). Zde lze usuzovat přímý vliv tohoto parametru na výsledek klasifikace. Hodnocením metod klasifikace krajinné pokrývky se zabýval ve své bakalářské práci Paluba (2018). Autor porovnával přesnosti klasifikovaných snímků Landsat 8 a Sentinel-2 pomocí algoritmů Maximum Likelihood a Support Vector Machine na území bývalých vojenských újezdů Brdy a Ralsko. V závěru konstatuje, že dosažením hodnoty celkové přesnosti vyšší než 85 % dosáhl uspokojivých výsledků. Rozdíl v celkové přesnosti mezi použitými algoritmy byl maximálně 5 % ve prospěch SVM. Dalšími, kdo se zabýval porovnáním klasifikačních algoritmů, byli Raczek a Zagajewski (2017). Ve své práci porovnávali klasifikační přesnosti algoritmů Support Vector Machine, Random Forest a Neural Network na území polské části krkonošského národního parku, za použití hyperspektrálních dat APEX. Nejvyšší celkové přesnosti 77 % bylo dosaženo užitím klasifikátoru Neural Network, který následuje s 68 % algoritmus Support Vector Machine. V práci byl také použit algoritmus Random Forest, který dosáhl obdobných hodnot přesnosti, jako SVM. Určení druhové skladby lesa z družicových dat se zabýval také Launer (2018), který klasifikací dat Sentinel-2 a Landsat 8 dosáhl celkové přesnosti vyšší než 88 %. Jak lze vidět z prezentovaných výsledků v předchozích větách, tak by alternativou použitých algoritmů v předkládané práci mohl být zvolen Random Forest. Ten však zatím není běžným nástrojem softwarů používaných v dnešní době.

7 ZÁVĚR

Předkládaná práce si kladla za cíl především porovnat a zhodnotit zvolené algoritmy řízené klasifikace družicových snímků. Nezbytnou součástí procesu klasifikace jsou trénovací a kontrolní množiny, kterým bylo v první polovině práce věnováno nemalé úsilí. Na základě hodnocení separability šesti zvolených tříd lesního porostu bylo vybráno více než 800 trénovacích a 670 kontrolních množin. Volba tříd lesního porostu, které byly v práci klasifikovány, vycházela ze zdrojů ÚHUL, který taktéž poskytl polygonovou vrstvu pro tvorbu nejvhodnějšího souboru trénovacích a kontrolních množin. Zpracovány byly volně dostupné snímky z družic Sentinel-2 a Landsat 8, které se liší počtem spektrálních pásem, ale i prostorovým rozlišením. Postupem uvedeným v metodice práce byly oba snímky předzpracovány. Zatímco snímek Landsat 8 na úrovni předzpracování Level 2 SR již obsahuje atmosférické korekce (LaSRC), data Sentinel-2 byly korigována v software SNAP pomocí zásuvného modulu Sen2Cor. V další fázi práce proběhla volba spektrálních pásem, kterými jsou B2–B7, B8a, B11 a B12 pro snímek z družice Sentinel-2. Spektrální pásma B2–B7 byla zvolena u druhého použitého snímku, tedy Landsat 8. Především na základě literatury byly provedeny klasifikace za použití algoritmů SVM, NN a ML. Nejlepších výsledků celkové přesnosti 62,62 % pro data Sentinel-2 a 53,40 % pro data Landsat 8 bylo u obou zpracovaných scén dosaženo klasifikátorem Neural Network s první modifikací parametrů (počet iterací = 3000, TR = 0,1 a TTC = 0,4). Rozdíl mezi hodnotami celkové přesnosti pro data Sentinel-2 a Landsat 8 dosáhl průměrně více než 14 %, což naplňuje cíl práce. Bylo prokázáno přesnější klasifikování snímku s lepším prostorovým rozlišením. Zde je však nutné podotknout, že většina citované literatury pracovala s menším územím a daty lepšího prostorového rozlišení. Ačkoliv bylo dosaženo podprůměrných hodnot celkové přesnosti vůči hodnotám v citované literatuře, lze konstatovat, že zpracovatelská přesnost klasifikace dosáhla u nejrozšířenějších typů lesního porostu ve většině případů hodnoty nad 80 %.

Výsledky předkládané práce mohou posloužit jako zdroj informací o kvalitách použitých klasifikačních algoritmů s ohledem na typ klasifikovaných dat a území. Dále lze konstatovat, že použitím polygonové vrstvy od ÚHUL je možné tvořit soubor trénovacích množin, jejichž klasifikací lze dosáhnout dobrých výsledků celkové přesnosti.

SEZNAM POUŽITÉ LITERATURY

ARCDATA (2018): ENVI. Dostupné z: <https://www.arcdata.cz/produkty/envi> [cit. 21. dubna 2018]

BOLSTAD, P., LILLESAND, T. M. (1991): Rapid maximum likelihood classification. Photogrammetric Engineering and Remote Sensing. Vydání 57, č. 1, s. 67–74.

CENIA (2016): Družice Sentinel. Dostupné z: <http://copernicus.gov.cz/druzice-sentinel> [cit. 21. dubna 2018]

DIVÍŠEK, J.; CULEK, M.; JIROUŠEK, M. (2010): Biogeografie. Multimediální výuková příručka. Geografický ústav, Přírodovědecká fakulta, Masarykova univerzita. Dostupné z: https://is.muni.cz/el/1431/jaro2010/Z0005/18118868/index_book_5-4-2.html

DOBROVOLNÝ, P. (1998): Dálkový průzkum Země: digitální zpracování obrazu. 1. vyd. Brno: Masarykova univerzita, 1998. 208 s.

ERBEK, F., S., ÖZKAN, C., TABERNER, M. (2004) Comparison of maximum likelihood classification method with supervised artificial neural network algorithms for land use activities. International Journal of Remote Sensing. Vydání 25, č. 9, s. 1733–1748.

ESA (2018): Heritage, Sentinel-2. Dostupné z: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/heritage> [cit. 21. dubna 2018]

HÁJEK, F., ADOLT, R., TOMANČÁK, O., KANTOROVÁ, M., KUČERA, M., ČECH, Z. (2016): Metodika a pracovní postupy fotogrammetrického šetření NIL2. ÚHUL. 168 s.

HARRIS GEOSPATIAL SOLUTIONS. ENVI. Dostupné z: <http://www.harrisgeospatial.com/SoftwareTechnology/ENVI.aspx> [cit. 21. dubna 2018]

HARRIS GEOSPATIAL SOLUTIONS. Clumping Classes. Using ENVI. Dostupné z: <http://www.harrisgeospatial.com/docs/ClumpingClasses.html> [cit. 21. dubna 2018]

HARRIS GEOSPATIAL SOLUTIONS. Sieving Classes. Using ENVI. Dostupné z: <http://www.harrisgeospatial.com/docs/SievingClasses.html> [cit. 21. dubna 2018]

HARRIS GEOSPATIAL SOLUTIONS. Calculate Confusion Matrices. Using ENVI. Dostupné z: <http://www.harrisgeospatial.com/docs/CalculatingConfusionMatrices.html> [cit. 21. dubna 2018]

HARRIS GEOSPATIAL SOLUTIONS. ENVI API. Support Vector Machine Background. Dostupné z: <https://www.harrisgeospatial.com/docs/backgroundsvmgeneral.html> [cit. 10. září 2017]

HARRIS GEOSPATIAL SOLUTIONS. Using ENVI. Neural Net. Dostupné z: <https://www.harrisgeospatial.com/docs/NeuralNet.html> [cit. 10. září 2017]

HEPNER, G., F. (1990): Artificial neural network classification using a minimal training set. Comparison to conventional supervised classification. *Photogrammetric Engineering and Remote Sensing*. Vydání 56, č. 4, s. 469–473.

HROMÁDKOVÁ, L. (2015): Classification of meadow vegetation in the Krkonoše Mts. using aerial hyperspectral data and support vector machines classifier. Diplomová práce. Univerzita Karlova v Praze, Přírodovědecká fakulta. 137 s.

HUANG, C.; DAVIS, L., S.; TOWNSHEND, J., R., G. (2000): An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*. Vydání 23, č. 4, s. 725–749.

HUANG, C.; HOMER, C.; Yang, L. (2003): Regional forest land cover characterization using Landsat type data. In: Wulder, M., Franklin, S. (Eds.), *Remote Sensing of Forests. Concepts and Case Studies.*, s. 389–410.

IMMITZER, M.; VUOLO, F.; ATZBERGER, C. (2016): First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe. *Remote Sensing*, 8, č. 166.

INGLADA, J. (2017): Carte d'occupation des sols 2016. Dostupné z: <http://osr-cesbio.ups-tlse.fr/~oso/posts/2017-03-30-carte-s2-2016/> [cit. 1. dubna 2017]

KOLÁŘ, J.; HALOUNOVÁ, L.; PAVELKA, K. (1997): Dálkový průzkum Země 10. 1. vyd. Praha: Vydavatelství ČVUT. 1997, 164 s.

KRÁSA, P. (2007): Květena ČR. BOTANY.CZ. Dostupné Z: <https://botany.cz/cs/rubrika/kvetena> [cit. 21. dubna 2018]

LAUNER, M. (2018): Určení druhové skladby lesa z družicových dat. Diplomová práce. Univerzita Karlova, Přírodovědecká fakulta. 133 s.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. (2011): Support vector machines in remote sensing: A review. ISPRS Journal of Photogrammetry and Remote Sensing. Vydání 66, č. 3, s. 247–259.

OUBRECHTOVÁ, V. (2012): Využití Umělých Neuronových Sítí v klasifikaci Land Cover. Diplomová práce. Univerzita Karlova v Praze, Přírodovědecká fakulta. 70 s.

PALUBA, D. (2018): Hodnotenie metód a vstupných dát pre účely klasifikácie krajiny pokrývky na príklade bývalých vojenských obvodov Brdy a Ralsko. Diplomová práce. Univerzita Karlova, Přírodovědecká fakulta. 78 s.

PLÍVA, K. (1971): Typologický systém ÚHUL. Ústav pro hospodářskou úpravu lesů Brandýs nad Labem, 90 s.

RACZKO, E., ZAGAJEWSKI, B. (2017): Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images, European Journal of Remote Sensing, Vydání 50, č. 1, s. 144–154.

RICHARDS, J.A.; JIA, X. (1999): Remote Sensing Digital Image Analysis: An Introduction. Springer-Verlag, New York Inc, 494 s.

SHAFRI, H. Z. M., RAMLE, F.S.H. (2009): A Comparison of Support Vector Machine and Decision Tree Classifications Using Satellite Data of Langkawi Island. Information Technology Journal. Vydání 8, č. 1, s. 64–70.

ŠMAUSOVÁ, B. (2016): Využití multispektrálních družicových dat pro klasifikaci lesních porostů poškozených disturbancemi. Diplomová práce. Univerzita Karlova v Praze, Přírodovědecká fakulta. 69 s.

TOPALOGLU, R., H.; SERTEL, E.; MUSAOGU, N. (2016): Assessment of Classification Accuracies of SENTINEL-2 and LANDSAT-8 Data for Land Cover / Use Mapping. International Archives of the Photogrammetry. Remote Sensing and Spatial Information Sciences. Vydání XLI-B8, 2016. s. 1055-1059.

USGS (2016): Landsat 8 (L8) Data Users Handbook. U. S. Geological Survey. 2. verze, 106 s.

ÚSTAV PRO HOSPODÁŘSKOU ÚPRAVU LESŮ (2017): Druhová skladba. Katalog mapových informací. Dostupné z: <http://www.uhul.cz/mapy-a-data/469-druhova-skladba> [cit. 21. dubna 2018]

ÚSTAV PRO HOSPODÁŘSKOU ÚPRAVU LESŮ (2001): Oblastní plány rozvoje lesů. PLO 7 Brdská vrchovina. 499 s. Dostupné z: <http://www.uhul.cz/nase-cinnost/oblastni-plany-rozvoje-lesu/prirodni-lesni-oblasti-plo/164-prirodni-lesni-oblast-c-7-brdska-vrchovina> [cit. 16. června 2017]

WULDER, M.; FRANKLIN, S. (2003): Remote Sensing of Forest Environments. Concepts and Case Studies. Kluwer Academic Publishers, The Netherlands, 519 s.

ZLATNÍK, A. (1956): Nástin lesnické typologie na biogeocenologickém základě a rozlišení československých lesů podle skupin lesních typů. Pěstění lesů III. Státní zemědělské Praha. s. 317–401.

Žubrietovský, L.; Švábová, L.; Šváb, O. (2017): Sentinel-2 – DATOVÉ SPECIFIKACE. Praha. 12 s. Dostupné z: <http://collgs.czechspaceportal.cz/sentinel-2-datove-specifikace> [cit. 21. dubna 2018]

SEZNAM POUŽITÝCH ZDROJŮ DAT

ArcČR 500: Digitální geografická databáze, verze 3. 3. Praha: ARCDATA Praha s.r.o.

Druhová skladba PLO 7 (polygonová vrstva z roku 2016). Poskytnuto v bezplatném rozsahu pro studijní účely. ÚHUL Brandýs nad Labem (cit. 23. 11. 2017).

INSPIRE datová sada pro téma Ortofotosnímky (prohlížeč služba WMS ortofoto). Dostupné z http://geoportal.cuzk.cz/WMS_INSPIRE_ORTOFOTO/WMSservice.aspx? (cit. 17. 7. 2018).

LC08_L1TP_192025_20160827_20170321_01_T1 (multispektrální snímek Landsat 8 z roku 2016). Staženo z EarthExplorer USGS. Dostupné z earthexplorer.usgs.gov (cit. 9. 10. 2017).

S2A_OPER_PRD_MSIL1C_PDMC_20160828T210754_R022_V20160827T101022_20160827T101025 (multispektrální snímek Sentinel-2 z roku 2016). Staženo Copernicus Open Access Hub. Dostupné ze scihub.copernicus.eu (cit. 9. 10. 2017).

SEZNAM PŘÍLOH

- Příloha 1: Chybová matice z výsledku klasifikace dat S2 algoritmem ML
- Příloha 2: Chybová matice z výsledku klasifikace dat S2 algoritmem SVM – RBF
- Příloha 3: Chybová matice z výsledku klasifikace dat S2 algoritmem SVM – POLY6
- Příloha 4: Chybová matice z výsledku klasifikace dat S2 algoritmem NN – Default
- Příloha 5: Chybová matice z výsledku klasifikace dat S2 algoritmem NN – Mod1
- Příloha 6: Chybová matice z výsledku klasifikace dat S2 algoritmem NN – Mod2
- Příloha 7: Chybová matice z výsledku klasifikace dat S2 algoritmem NN – Mod3
- Příloha 8: Chybová matice z výsledku klasifikace dat L8 algoritmem ML
- Příloha 9: Chybová matice z výsledku klasifikace dat L8 algoritmem SVM – RBF
- Příloha 10: Chybová matice z výsledku klasifikace dat L8 algoritmem SVM – Poly6
- Příloha 11: Chybová matice z výsledku klasifikace dat L8 algoritmem NN – Default
- Příloha 12: Chybová matice z výsledku klasifikace dat L8 algoritmem NN – Mod1
- Příloha 13: Chybová matice z výsledku klasifikace dat L8 algoritmem NN – Mod2
- Příloha 14: Chybová matice z výsledku klasifikace dat L8 algoritmem NN – Mod3
- Příloha 15: CD s elektronickou verzí diplomové práce a mapami ve formátu A3

Příloha 1: Chybová matice z výsledku klasifikace dat Sentinel-2 algoritmem ML. Tučně vyznačená hodnota představuje celkovou přesnost (zdroj: vlastní zpracování)

[illegible]

Příloha 2: Chybová matice z výsledku klasifikace dat Sentinel-2 algoritmem SVM – RBF. Tučně vyznačená hodnota představuje celkovou přesnost (zdroj: vlastní zpracování)

[illegible]

Příloha 3: Chybová matice z výsledku klasifikace dat Sentinel-2 algoritmem SVM – POLY6. Tučně vyznačená hodnota představuje celkovou přesnost (zdroj: vlastní zpracování)

[illegible]

Příloha 4: Chybová matice z výsledku klasifikace dat Sentinel-2 algoritmem NN – Default. Tučně vyznačená hodnota představuje celkovou přesnost (zdroj: vlastní zpracování)

[illegible]

Příloha 7: Chybová matice z výsledku klasifikace dat Sentinel-2 algoritmem NN – Mod3. Tučně vyznačená hodnota představuje celkovou přesnost (zdroj: vlastní zpracování)

[illegible]

Příloha 8: Chybová matice z výsledku klasifikace dat Landsat 8 algoritmem ML. Tučně vyznačená hodnota představuje celkovou přesnost (zdroj: vlastní zpracování)

[illegible]

Příloha 9: Chybová matice z výsledku klasifikace dat Landsat 8 algoritmem SVM – RBF. Tučně vyznačená hodnota představuje celkovou přesnost (zdroj: vlastní zpracování)

[illegible]

Příloha 10: Chybová matice z výsledku klasifikace dat Landsat 8 algoritmem SVM – Poly6. Tučně vyznačená hodnota představuje celkovou přesnost (zdroj: vlastní zpracování)

[illegible]

Příloha 11: Chybová matice z výsledku klasifikace dat Landsat 8 algoritmem NN – Default. Tučně vyznačená hodnota představuje celkovou přesnost (zdroj: vlastní zpracování)

[illegible]

Příloha 12: Chybová matice z výsledku klasifikace dat Landsat 8 algoritmem NN – Mod.1.
Tučně vyznačená hodnota představuje celkovou přesnost (zdroj: vlastní zpracování)

[illegible]

Příloha 15: CD s elektronickou verzí diplomové práce a mapami ve formátu A3

- Elektronická verze diplomové práce ve formátu PDF/A
- Mapy klasifikovaného území ve formátu A3